

# Системы интеллектуального менеджмента для цифрового земледелия. Часть 1

Н. Н. Бахтадзе<sup>1</sup>, Е. М. Максимов<sup>1</sup>, Н. Е. Максимова<sup>1</sup>, Д. М. Дончан<sup>1</sup>, Д. С. Кузнецов<sup>II</sup>,  
Э. А. Захаров<sup>III</sup>

<sup>I</sup> Институт проблем управления им. В.А. Трапезникова РАН, Москва, Россия

<sup>II</sup> Национальный университет науки и технологий МИСиС, Москва, Россия

<sup>III</sup> Московский физико-технический институт, Москва, Россия

**Аннотация.** В статье представлен подход к созданию информационных систем для цифрового земледелия, позволяющих на базе информационных технологий и интеллектуальных прогнозирующих моделей более рационально планировать использование земель, расходовать удобрения и горючее, что снижает себестоимость производимой продукции и повышает эффективность сельскохозяйственного производства. Кроме того, может быть достигнут долгосрочный агрономический и экологический эффект - за счет более бережной обработки почвы и уменьшения применения азотных удобрений. Разработаны принципы создания базы знаний и построения моделей урожайности зерновых культур в зависимости от режима внесения минеральных удобрений на основе интеллектуальных алгоритмов идентификации, а также моделей прогнозирования цен на продукцию цифрового земледелия.

**Ключевые слова:** цифровое земледелие, мягкие датчики, прогнозирующие модели, управление знаниями.

DOI 10.14357/20718632200208

## Введение

Агроменеджмент сегодня активно использует возможности информационных технологий – как для реализации более эффективного управления определенным технологическим процессом, так и для организации наиболее прибыльного ведения хозяйства в целом для конкретных сельхозпредприятий, с учетом специфики их деятельности и текущей ситуации. В данной статье мы рассмотрим некоторые задачи обоих уровней.

В Части I данной статьи, прежде всего, предлагается подход к поддержке эффективного (в технологическом и экономическом аспектах) управления хозяйством, основанный на использовании прогнозирующих идентификационных моделей. Далее, исследуется управление

технологическими процессами, в частности, режимом внесения минеральных удобрений, с целью получения наиболее высокой урожайности зерновых культур (одна из типовых задач *цифрового земледелия*). Поддержка управления осуществляется на основе интеллектуальных прогнозирующих моделей. Интеллектуальность здесь понимается в аспекте использования *индуктивных знаний* о динамическом процессе [1, 2], т. е. определенных статистических закономерностей, извлекаемых из всего массива исторических данных с помощью алгоритмов интеллектуального анализа (Data Mining).

*Цифровое земледелие* представляет собой высокотехнологичный подход к управлению состоянием полей и эффективностью их использования на основе исследования динамики

их физических и агрохимических свойств с помощью современных математических и информационных технологий.

Управление в рамках концепции цифрового земледелия основывается на принципе, при котором поле, неоднородное по рельефу, почвенному покрову или агрохимическому содержанию, подвергается неоднородной обработке. Выявление неоднородностей осуществляется на основе анализа работы систем глобального позиционирования, аэро-фото- и космических снимков, геоинформационных систем, статистического анализа и экспертных знаний. На основе анализа данных, характеризующих особенности участков, с учетом особенностей типов почв и климатических условий, осуществляются: планирование посева, расчёт количества внесения удобрений, прогноз урожайности и финансовое планирование.

Такой подход позволяет более рационально расходовать удобрения и горючее, что снижает себестоимость производимой продукции и повышает эффективность сельскохозяйственного производства. Кроме того, может быть достигнут долгосрочный агрономический и экологический эффект – за счет более бережной обработки почвы и уменьшения интенсивности применения азотных удобрений.

В числе современных методов и средств агроменеджмента можно выделить: технологии глобального позиционирования (GPS, ГЛОНАСС), геоинформационные системы (GIS), технологии текущей оценки урожайности (Yield Monitor Technologies), технологии переменного нормирования (Variable Rate Technology), технологии дистанционного зондирования земли (ДЗЗ), интернет вещей, и т.д.

В Части 2 статьи будут рассмотрены еще две задачи – прогнозирование показателей вегетации на основе анализа данных дистанционного зондирования земли (ДЗЗ) и методы прогнозирования цены на сельскохозяйственную продукцию для определенного региона.

## 1. Концепция архитектуры информационно-управляющих комплексов для систем поддержки принятия решений

Для эффективного управления работой сельхозпредприятий предлагается создание



Рис. 1. Система поддержки принятия решений по управлению производственной деятельностью сельхозпредприятий

систем поддержки принятия решений на основе базы формализованных технологических знаний и интеллектуальных прогнозирующих моделей. Под *индуктивными знаниями* [1] понимаются закономерности, получаемые на основе интеллектуального анализа производственных данных. Общая схема такой Системы поддержки принятия решений представлена на Рис. 1.

В 2018-2018 гг. в ИПУ РАН была разработана и поддерживается база данных «АПК-Интеграция», содержащая архивную и актуальную производственную информацию для сельхозпредприятий различных регионов Российской Федерации. Данные поступают: из хозяйств (сельхозпредприятий), из баз данных научных сельскохозяйственных институтов (НИИ СХ). Здесь же должны содержаться данные по дистанционному зондированию земель (ДЗЗ), данные, получаемые с помощью беспилотных летающих аппаратов (БПЛА).

В системе формируются *Базы индуктивных знаний* (закономерности, извлекаемые на основе интеллектуального анализа данных – *knowledge discovery in databases*, банк алгоритмов обработки данных и построения предиктивных моделей, информационные модели для различных производственных процессов, архив идентификационных моделей. Здесь же содержатся: модели и результаты прогнозирования на прошлых этапах, прошлые сценарии управления в ситуациях, сходных с текущей в смысле определенных критериев, и т.п.). Система предназначена для решения разных производ-



Рис. 2. Схема корректировки Технологической карты

ственных задач на базе одних и тех же информационных массивов и знаний.

На основе анализа различных рассчитываемых либо прогнозируемых показателей (например, расчетные значения коэффициента использования питательных веществ из почвы; расчетные значения коэффициента использования питательных веществ из удобрений; расчетные значения прибыли при задаваемых значениях урожайности и рыночной цены; прогнозируемые значения прибыли с учетом уточненных значений коэффициентов использования питательных веществ, с поправкой на погодные условия; прогнозируемые значения изменения процентного содержания NPK (N – азот, P – фосфор, K – калий – элементы, жизненно важные для питания и развития растений) в почве за сезон; прогнозируемые значения роста урожайности при данной схеме внесения удобрений и т.д.), формируется предложение по изменению Технологической карты

(Рис. 2), содержащей в себе показатели всех операций, выполняемых на поле. По сути, Технологическая карта формирует инструкцию по текущему управлению производственным процессом данного сельхозпредприятия.

Для формирования Технологической карты по расчетным и прогнозируемым показателям создается финансово-экономическая модель конкретного предприятия.

## 2. Финансово-экономическая модель

Пользователь в интерактивном режиме выбирает конкретный участок (поле). Автоматически подгружаются значения параметров: кадастровая стоимость участка, стоимость аренды участка, площадь (посева /уборки). Далее подгружается информация по выполненным операциям за прошедший сезон, некоторые данные пользователь вводит интерактивно.

- Наименование культуры.
- Количество семян, кг.
- Стоимость семян, р/кг.
- Количество удобрений, кг.
- Стоимость удобрений, р/кг.
- Площадь поражения (болезни/вредители), га.
- Количество химикатов, кг.
- Стоимость химикатов, р/кг.
- Выход продукции после доработки, ц/га.
- Цена реализации за ц, р.
- Количество техники требуемое, шт.
- Количество техники имеющееся, шт.
- Остаточная стоимость (в т.ч. амортизация), р.
- Объем услуг аутсорсинга, ед.

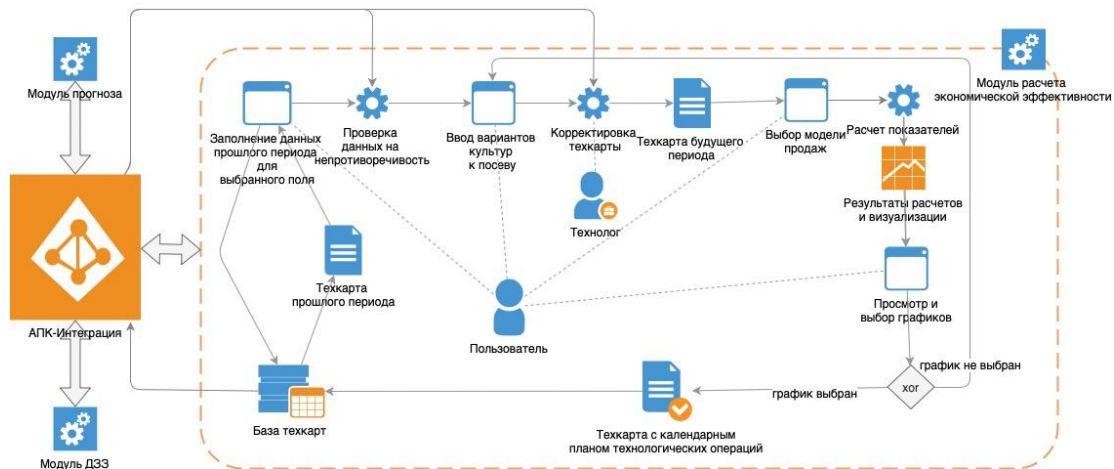


Рис. 3. Архитектура модуля финансово-экономической модели

- Стоимость услуг аутсорсинга, р.

Далее загружается Технологическая карта за прошедший сезон с информацией по имеющемуся парку техники. Интерактивно пользователь задает информацию по культурам, рассматриваемым к высадке на поле в следующем сезоне (это могут быть разные культуры либо одна культура с использованием различных технологий земледелия; как следствие, урожайность (в соответствии с формируемым прогнозом) может быть различной). Далее пользователь выбирает модель продаж: сдать в элеватор, продавать партиями и т.д. по каждой культуре в натуральном выражении. Пользователь также определяет желаемую цену реализации урожая за тонну.

В модель продаж также может быть добавлена возможность расчета торговой наценки и себестоимости по каждой культуре с разной

урожайностью. Пользователь задает дату начала продаж, цену, а также начальный и максимальный объемы продаж (Табл. 1).

Модель расходов формируется следующим образом для каждого периода:

Параметры техкарт + стоимость удобрений + стоимость семян + стоимость услуг аутсорсинга. Также рассчитываются: денежный поток ДП = Продажи - Затраты + Заемные средства; дисконтирование в каждом периоде и уточненный период окупаемости (Табл. 2).

В результате работы расчетного модуля формируются графики, иллюстрирующие динамику накопленного сальдо денежных потоков, и показатели экономической эффективности поля по каждой культуре (Рис. 4).

Пользователь выбирает вариант, который он считает оптимальным, после чего получает де-

Табл. 1. Динамика натурального объема продаж

Динамика натурального объема продаж	01.06.2018	01.07.2018	01.08.2018	01.09.2018	01.10.2018	01.11.2018
Озимая пшеница 55			900	800	650	700
Белокочанная капуста 600	100	300	250	150	400	200
Озимая пшеница 50			810	720	585	630
Белокочанная капуста 550	180	250	300	200	250	200

Табл. 2. Динамика объема продаж в денежном выражении

Озимая пшеница 55	1	2	3	4	5	6
<b>Денежные потоки</b>						
Затраты	70951,13	84078,93	300023,16	137496,34	200105,30	125443,57
Продажи	0,00	0,00	0,00	0,00	0,00	0,00
Заемные средства						
Денежный поток (Cash Flow)	-70 951	-84 079	-300 023	-137 496	-200 105	-125 444
Кумулятивный Cash Flow	-70 951	-155 030	-455 053	-592 550	-792 655	-918 098
Коэффициент дисконтирования	0,8782	0,7713	0,6774	0,5949	0,5224	0,4588
Дисконтированный денежный поток (DCF)	-62 311	-64 849	-203 227	-81 795	-104 545	-57 557
Кумулятивный DCF	-62 311	-127 161	-330 388	-412 183	-516 728	-574 285
	Недисконтир	Дисконтир				
Период окупаемости (мес)	9	12				
	869 148	58 323				
	39 616	98 773				
Уточненный период окупаемости (мес)	9,95	11,31				

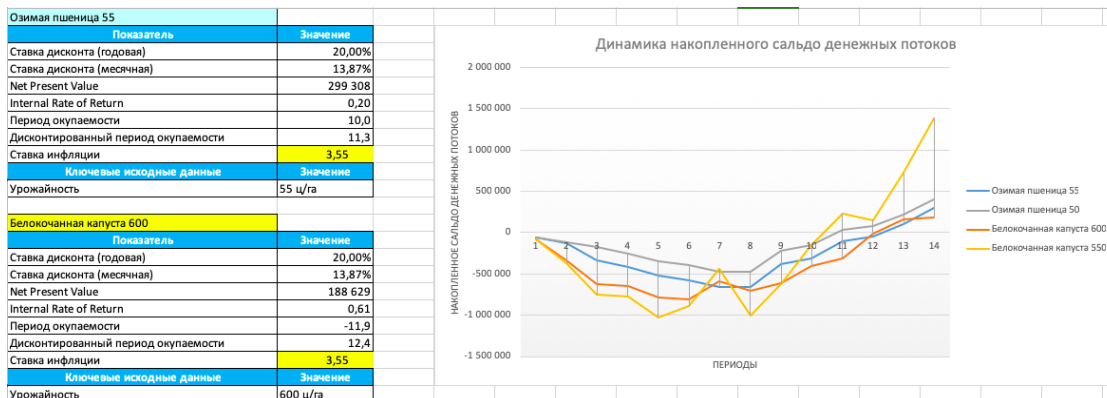


Рис. 4. Динамика сальдо денежных потоков

тализированный выбранный вариант в виде календарного плана технологических операций – напоминания и оповещения о том, «Что? Когда? В каком объеме?» и «За какую стоимость?» предстоит делать в новом сезоне.

Таким образом, была создана основа для формирования и коррекции в интерактивном режиме технологических карт сельхозпредприятия на основе прогнозов по различным показателям.

Следующим шагом явилась разработка прогнозирующих моделей различных технологических и экономических показателей для оптимизации процесса управления производственным процессом предприятия с учетом текущей ситуации.

### **3. Прогнозирующие модели для управления технологическими процессами сельхозпредприятий**

Одной из основных технологий цифрового земледелия является специализированная методика внесения удобрений - *внесение дифференцированным способом*, в зависимости от результатов анализа особенностей участков поля.

На основе спутниковой навигации, бортовых компьютеров и автоматизированных устройств сельскохозяйственного назначения и разнообразных датчиков фиксируются различные показатели для всех участков поля, такие как: температура почвы, приземного слоя и воздуха, скорость ветра, количество осадков и т. п. Наличие комплексной информации позволяет специалистам принимать адекватные решения и оперативно корректировать ситуацию на полях.

В настоящее время за рубежом комплексные системы дифференцированного внесения азотных удобрений применяются достаточно широко. Внедряются они и в России. Однако эти системы являются дорогостоящими и предоставляют далеко не всю возможную информацию о динамике свойств фрагментов поля, влияющей на рост урожайности и определяющей нормы внесения удобрений. Не менее затратным и трудоемким является подход, основанный на извлечении данных с нескольких датчиков, с последующей обработкой посредством специализированного программного обеспечения.

Альтернативой может быть разработка т.н. *мягких датчиков (Soft Sensors)* – виртуальных анализаторов, позволяющих строить прогнозирующие модели различных показателей для участков полей, основанные на интеллектуальном анализе уже доступных измерению текущих и архивных данных (не только по исследуемому полю, но и по другим, в определенном смысле «похожим» полям) и на создании *баз знаний*. Под *знаниями* понимаются извлекаемые из анализа данных закономерности, уточняемые по мере накопления информации [1, 2].

Для построения моделей прогнозирования ключевых показателей осуществлена разработка высокоточных алгоритмов предиктивной идентификации, основанных на *ассоциативном поиске* – одном из методов интеллектуального анализа данных [3].

Для построения модели формируется временная база данных архивной и текущей технологической информации. После определения прогноза выхода по текущему состоянию объекта эта виртуальная база уничтожается без запоминания. Алгоритм не настраивает аппроксимирующую модель реального процесса – он строит новую модель для каждого момента времени, при этом оценки параметров в любой момент времени являются наилучшими в смысле минимума среднеквадратической ошибки.

#### **3.1. Алгоритм ассоциативного поиска**

Представляет собой процедуру, основанную на интеллектуальном анализе данных, в частности, используются методы кластеризации. На основе этих методов в исследуемый момент времени из архива данных выбирается множество входов (в общем случае, многомерных), близких к текущему входному вектору в смысле определенного критерия. Последний получил название *ассоциативного импульса* и может быть как функционалом, так и логической либо нечеткой функцией.

Далее на основе классического (не рекуррентного) метода наименьших квадратов (МНК) определяется значение выхода в следующий момент времени. В предположении, что входные воздействия удовлетворяют условиям Гаусса-Маркова, оценки, получаемые по методу наименьших квадратов, являются состоятельными, несмещенными, статистически

эффективными. Преимущество такого подхода заключается в том, что он позволяет строить локально линейные модели для объектов, характеризующихся самыми различными видами нелинейностей.

Сохраняя все преимущества метода наименьших квадратов, данный метод, в отличие от МНК, использует только определенную информацию о динамике объекта (векторы входов в определенный момент времени из прошлого и соответствующие им выходы) – в соответствии с определенным критерием выбора этой информации из архива, что существенно редуцирует модель.

Таким образом, определяя критерий выбора данных из архива для построения модели, можно говорить о закономерностях, извлекаемых из исторических данных функционирования объекта, то есть о реализации *интеллектуального подхода к построению идентификационных моделей*. Интеллектуальность заключается в формировании индуктивных знаний (*Knowledge Based*), извлекаемых из исторических данных на основе их анализа (*Data Mining*).

Процесс формирования (извлечения) знаний в интеллектуальной системе сводится к восстановлению (ассоциативному поиску) *знания* по его фрагменту. При этом *знание* можно интерпретировать как *ассоциативную связь между образами*. В качестве *образа* будем использовать «наборы признаков», т. е. компонент векторов входов, входных переменных, или, как их часто называют на производстве, *входных параметров*.

*Критерий близости между образами* может формулироваться самыми различными способами. В самом общем случае он может быть представлен в виде логической функции - предиката. В частном случае, когда наборы признаков представляют собой векторы в  $n$ -мерном пространстве, критерий близости может представлять собой расстояние в этом пространстве.

Процесс ассоциативного поиска может осуществляться либо как процесс восстановления образа по частично заданным признакам (или восстановления фрагмента знания в условиях неполной информации; как правило, именно этот процесс имитируется в различных *моделях ассоциативной памяти*), либо - как процесс поиска связанных ассоциативно с данным обра-

зом других образов, привязанных к другим моментам времени.

В работах [3-6] предложен подход к формированию поддержки принятия решения об управлении, основанный на динамическом моделировании процедуры ассоциативного поиска. Были представлены результаты внедрения разработанных авторами алгоритмов ассоциативного поиска для технологических процессов химического и нефтеперерабатывающего производства, процессов управления в интеллектуальных энергосетях (*smart grids*), процессов трейдинга, процессов транспортной логистики.

Таким образом, метод ассоциативного поиска предполагает не аппроксимацию реального процесса во времени, а построение линейной модели нелинейного динамического объекта, новой в любой момент времени, с использованием наборов исторических данных («ассоциаций»), сформированных на этапе обучения и адаптивно корректируемых в соответствии с определенными критериями.

Линейная динамическая модель имеет следующий вид:

$$y_N = \sum_{i=1}^m a_i y_{N-i} + \sum_{j=1}^n \sum_{s=1}^S b_{js} x_{N-j,s}, \forall j \in 1, \dots, N \quad (1)$$

где  $y_N$  – прогноз выхода объекта на момент времени  $N$ ,

- $x_N$  – вектор входных воздействий,
- $m$  – глубина памяти по выходу,
- $n$  – глубина памяти по входу,
- $s$  – размерность вектора входов.

Заметим, что, несмотря на формальное сходство, модель не является классической регрессионной: для ее построения из архива входных данных выбирается не весь динамический хронологический «хвост», а лишь определенные входы, выбираемые из архива в соответствии с определенным критерием близости к текущему вектору входов.

Пример критерия отбора векторов описан ниже. Размерность этой гиперповерхности выбирается эвристически.

Таким образом, в формуле (9)  $n$  представляет собой количество векторов из архива (от момента времени 1 до момента  $N$ ), выбранных по критерию ассоциативного поиска. На каждом отрезке времени  $\{N-1, N\}$  выбирается определенный набор из  $n$  векторов,  $1 \leq n \leq N$ .

### 3.2. Критерий отбора входных векторов из архива

Для построения ассоциативной виртуальной модели в данный момент времени по текущему состоянию объекта критерий отбора входных векторов из архива может быть следующим. Введем в качестве расстояния (нормы в  $\mathbb{R}^s$ ) между точками  $S$ -мерного пространства входов величину:

$$d_{N,N-j} = \sum_{s=1}^S |x_{Ns} - x_{N-j,s}|, \quad \forall j \in 1, \dots, N, \quad (2)$$

где  $x_{Ns}$  – компоненты вектора входов в текущий момент времени  $N$  – т.н. *Манхэттенское расстояние*.

В силу одного из свойств нормы («неравенство треугольника») имеем:

$$d_{N,N-j} \leq \sum_{s=1}^S |x_{Ns}| + \sum_{s=1}^S |x_{N-j,s}|, \quad (3)$$

Пусть для текущего вектора входов  $x_N$ :

$$\sum_{s=1}^S |x_{Ns}| = d_N. \quad (4)$$

Для построения аппроксимирующей гиперповерхности для  $x_{N-j}$   $j=1, \dots, N$  отберем из архива входных данных такие векторы  $x_{N-j}$ , что для некоторого заданного  $D_N$  будет выполнено условие:

$$d_{N,N-j} \leq d_N + \sum_{s=1}^S |x_{N-j,s}| \leq D_N, \quad \forall j \in 1, \dots, N, \quad (5)$$

где  $D_N$  может быть выбрано, например, из условия:

$$D_N \geq 2d_N^{\max} = 2 \max_j \sum_{s=1}^S |x_{N-j,s}| \quad (6)$$

Если в выбранной области не наберется достаточного количества входов для применения МНК, т.е. соответствующая система линейных уравнений окажется несовместной, то выбранный критерий отбора точек в пространстве входов можно будет ослабить за счет увеличения порога  $D_N$ .

### 3.3. Ассоциативный поиск на основе кластеризации

В целях увеличения быстродействия алгоритма идентификации (как на этапе обучения, так и при последующем реальном функциони-

ровании объекта) используется один из методов интеллектуального анализа данных – кластеризация (динамическая классификация, автоматическая группировка данных, «обучение без учителя»). Методов кластеризации известно множество: иерархические алгоритмы,  $k$ -Means алгоритм, алгоритм минимального покрывающего дерева, метод ближайшего соседа, и т.д. Все они определяют принадлежность точки в многомерном пространстве к одной из областей, на которые это пространство разбивается.

В результате в каждый момент времени каждая исследуемая точка в многомерном пространстве может быть отнесена к какой-либо группе посредством присвоения ей кластерной метки. В задаче ассоциативного поиска для выбора векторов входов, «близких» к текущему, метка кластера определяется в соответствии с критерием ассоциативного отбора входных векторов из архива. Для построения виртуальных моделей векторы отбираются внутри соответствующего кластера.

Алгоритмы продемонстрировали высокоточные результаты для нелинейных нестационарных объектов в промышленности и энергетике. Как показано ниже, применение таких алгоритмов в системах агроменеджмента позволит синтезировать эффективные решения по управлению в системах цифрового земледелия.

Рассмотрим результаты построения интеллектуальных прогнозирующих идентификационных моделей для прогнозирования урожайности зерновых культур в зависимости от значений различных показателей, характеризующих текущую производственную ситуацию.

### 3.4. База данных для построения моделей прогнозирования урожайности

На основе данных аналитических схем и интеллектуальных статистических алгоритмов ассоциативного поиска были разработаны модели прогнозирования урожайности на примере исследования динамики урожайности пшеницы для ряда областей РФ.

Прогноз урожайности для конкретного поля осуществляется на основе анализа динамики нескольких показателей. Были проанализированы как природные факторы, так и показатели, определяемые режимом земледелия.



Для исследования и построения модели прогноза были отобраны следующие факторы:

- почвенно-климатическая зона;
- климатическая характеристика за последние 10 лет: осадки помесячно, среднесуточная температура воздуха помесячно;
- запас влаги в слое почвы до 1 м в критические фазы развития зерновых: посев–всходы, кущение- трубкавание, колошение–налив.

В дальнейших исследованиях планируется учитывать:

- запас влаги в слое почвы до 1 м в критические фазы развития зерновых: посев-всходы, кущение-трубкавание, колошение-налив;
- история поля за последние 7-10 лет:
  - предшествующие и возделываемые в настоящее время культуры,
  - урожайность культур (планируется учитывать также качество зерна),
  - количество (дозы) внесенных минеральных удобрений под предшествующую культуру и под возделываемую культуру, включая периодичность и дозы внесения азотных удобрений.

Прогноз урожайности пшеницы для конкретного поля осуществляется на основе анализа динамики выбранных показателей. Были запрошены и получены данные о возделывании и

его результатах от более чем 30 различных НИИСХ.

Планируется также учитывать в модели при дальнейших исследованиях:

- почвенную характеристику поля, включая: почвенную разность, содержание гумуса, механический состав и кислотность рН (для дерново-подзолистых и серых лесных почв),
- рельеф поля, включая крутизну склонов, экспозицию склонов, замкнутость элементов рельефа,
- обеспеченность почвы элементами питания: фосфор, калий (в пахотном слое) - один раз в 5 лет или после уборки предшествующей культуры и азот – ежегодно весной, до внесения азотных удобрений в начале вегетации в верхнем слое почвы (до 60 см).

Экспериментальная база данных содержит информацию от 30 агрохозяйств (Рис. 5).

При помощи статистического анализа и применения алгоритмов ассоциативного поиска был произведен анализ влияния различных факторов на урожайность основных зерновых культур. Далее была разработана База индуктивных знаний.

### 3.5. Результаты моделирования

Далее, при помощи статистического анализа и применения алгоритмов ассоциативного

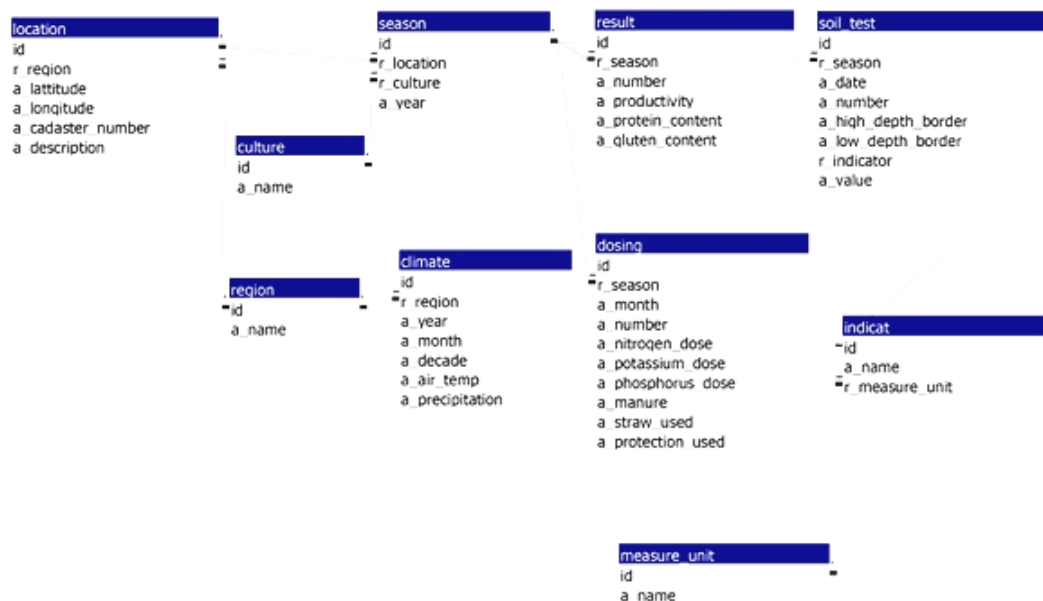


Рис. 5. Структура базы данных



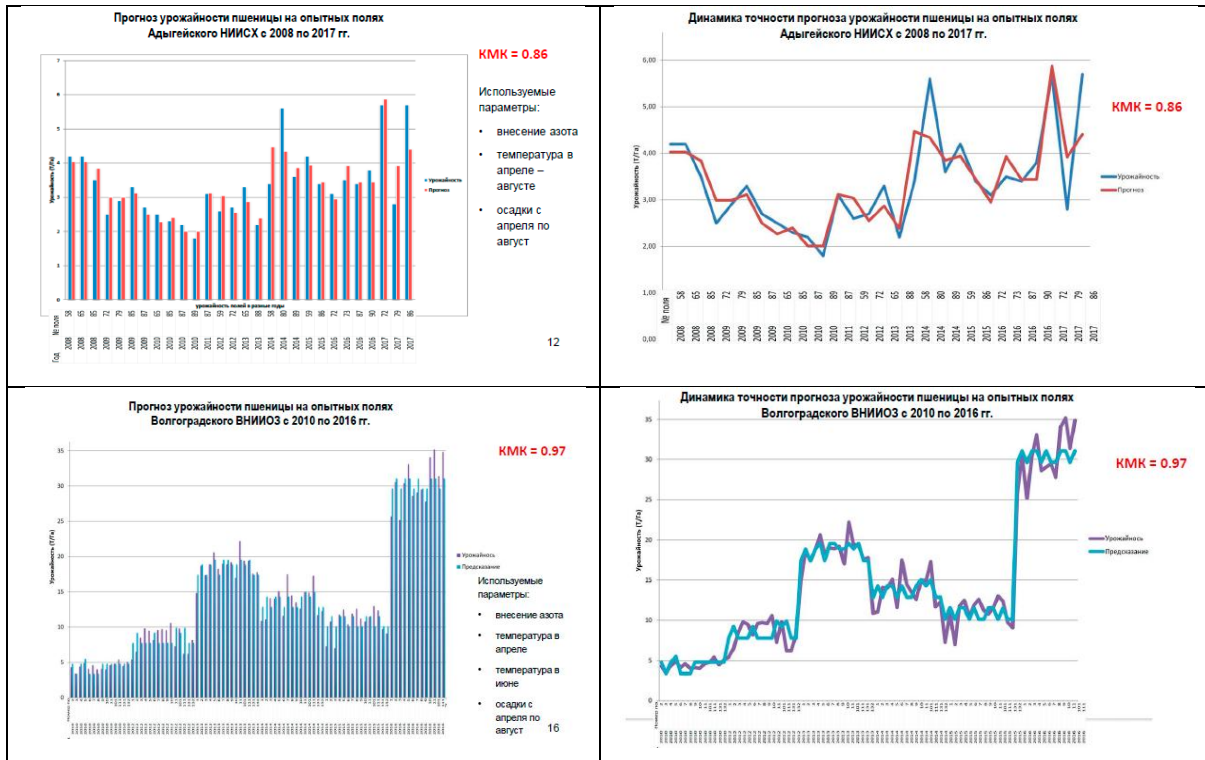


Рис. 6. Результаты моделирования

поиска были построены прогнозирующие модели влияния различных факторов на урожайность основных зерновых культур. На Рис. 6 приведены примеры результатов моделирования прогноза урожайности для разных регионов России и соответствующие значения множественного коэффициента корреляции.

#### 4. Разработка прогнозирующих моделей для оптимизации процесса управления производственным процессом предприятия с учетом текущей ситуации

Предложенные алгоритмы могут быть использованы также для прогнозирования различных экономических показателей – как отдельного хозяйства, так и их совокупностей, демонстрируя возможности организации эффективного управления деятельностью сельхозпредприятий на основе интеллектуальных методов и алгоритмов предиктивной идентификации. Например, можно прогнозировать

#### Предварительный анализ и классификация показателей из Базы данных

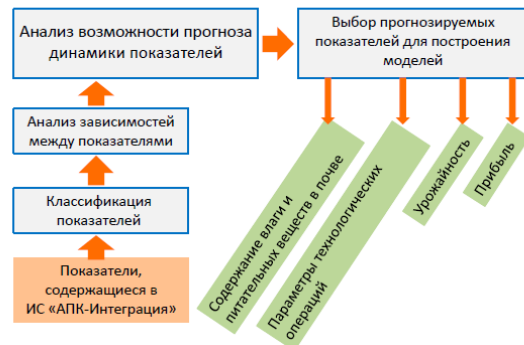


Рис. 7. Предварительный анализ исследуемых показателей

цены на сельскохозяйственную продукцию для определенного региона.

На основе предварительного анализа этих показателей (Рис. 7) были созданы функциональные схемы основных бизнес-процессов этой системы с указанием информационных потоков.

Были предложены Функционально-аналитические схемы для поддержки принятия решений для разных решаемых Системой производствен-

ных задач, с указанием схем информационных потоков. На Рис. 8 приведены примеры таких схем. Также предложены схемы для расчета динамики аналитических показателей в зависимости от значений основных производственных параметров (Рис. 9).

Нормы внесения удобрений, необходимые для получения желаемой урожайности, рассчитываются с учетом содержания NPK в пахотном слое почвы, а также показателей, характеризующих процесс усвоения элементов питания растениями: выноса питательных веществ с урожаем; коэффициента использования

питательных веществ почвы; коэффициента использования удобрений.

Значения данных показателей, приводимые в различных источниках, существенно отличаются друг от друга и являются либо усредненными, как в [7-10], либо полученными в ходе экспериментов для определенных культур, выращиваемых в определенном регионе на определенном типе почв [11-15]. Это говорит о том, что не существует общепринятых значений указанных коэффициентов – ввиду их изменчивости и зависимости от вида и сорта культуры, типа почвы, ее водно-физических свойств, климатической зоны.

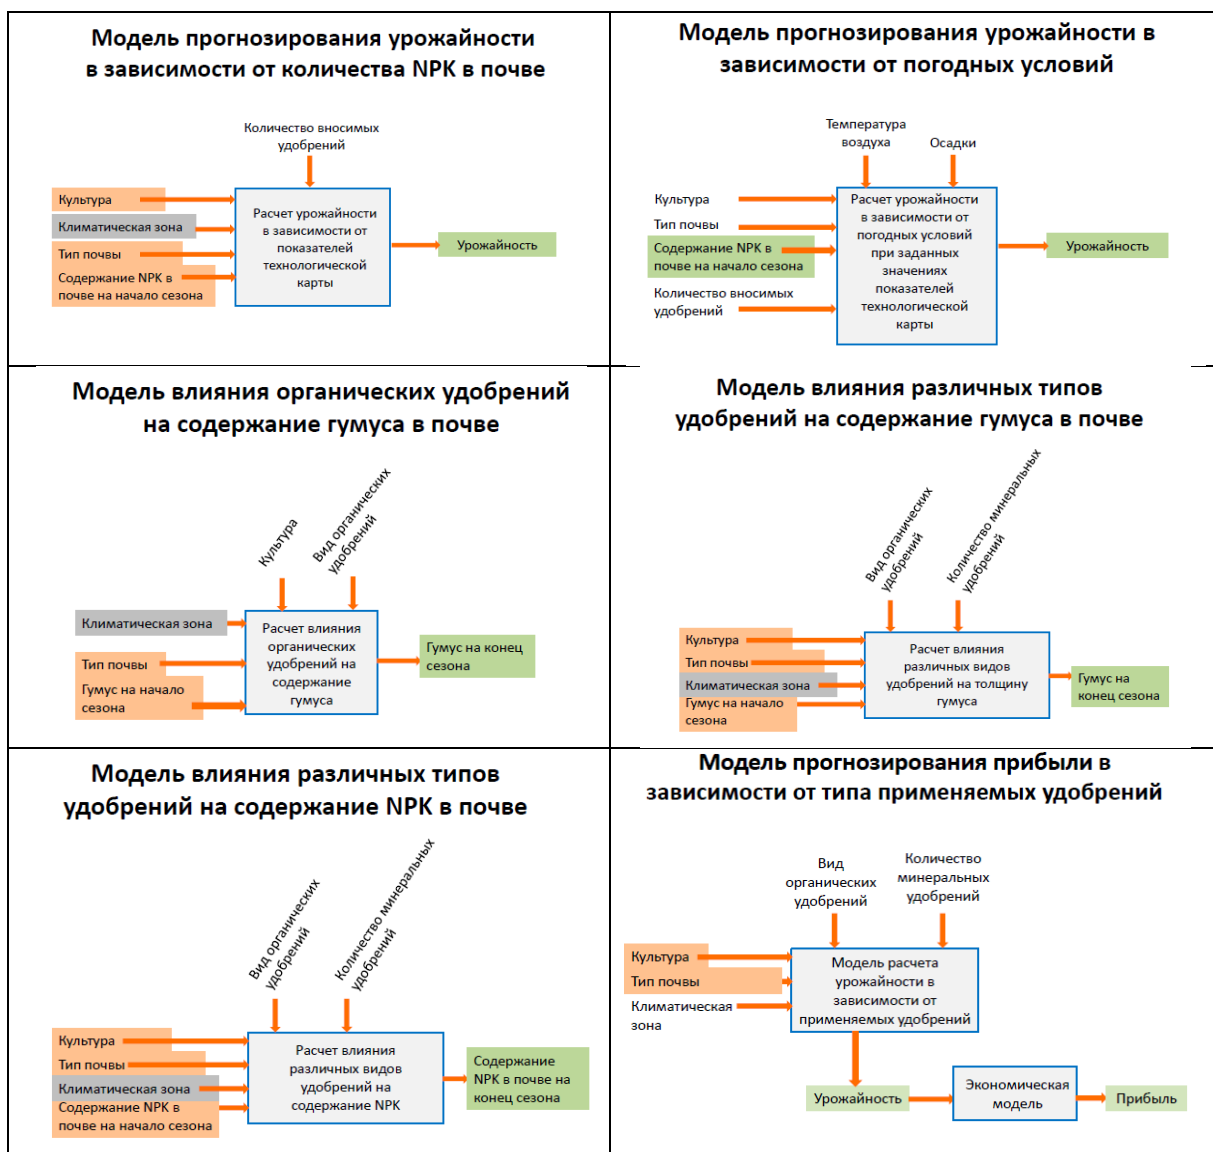


Рис. 8. Функциональные схемы основных бизнес-процессов

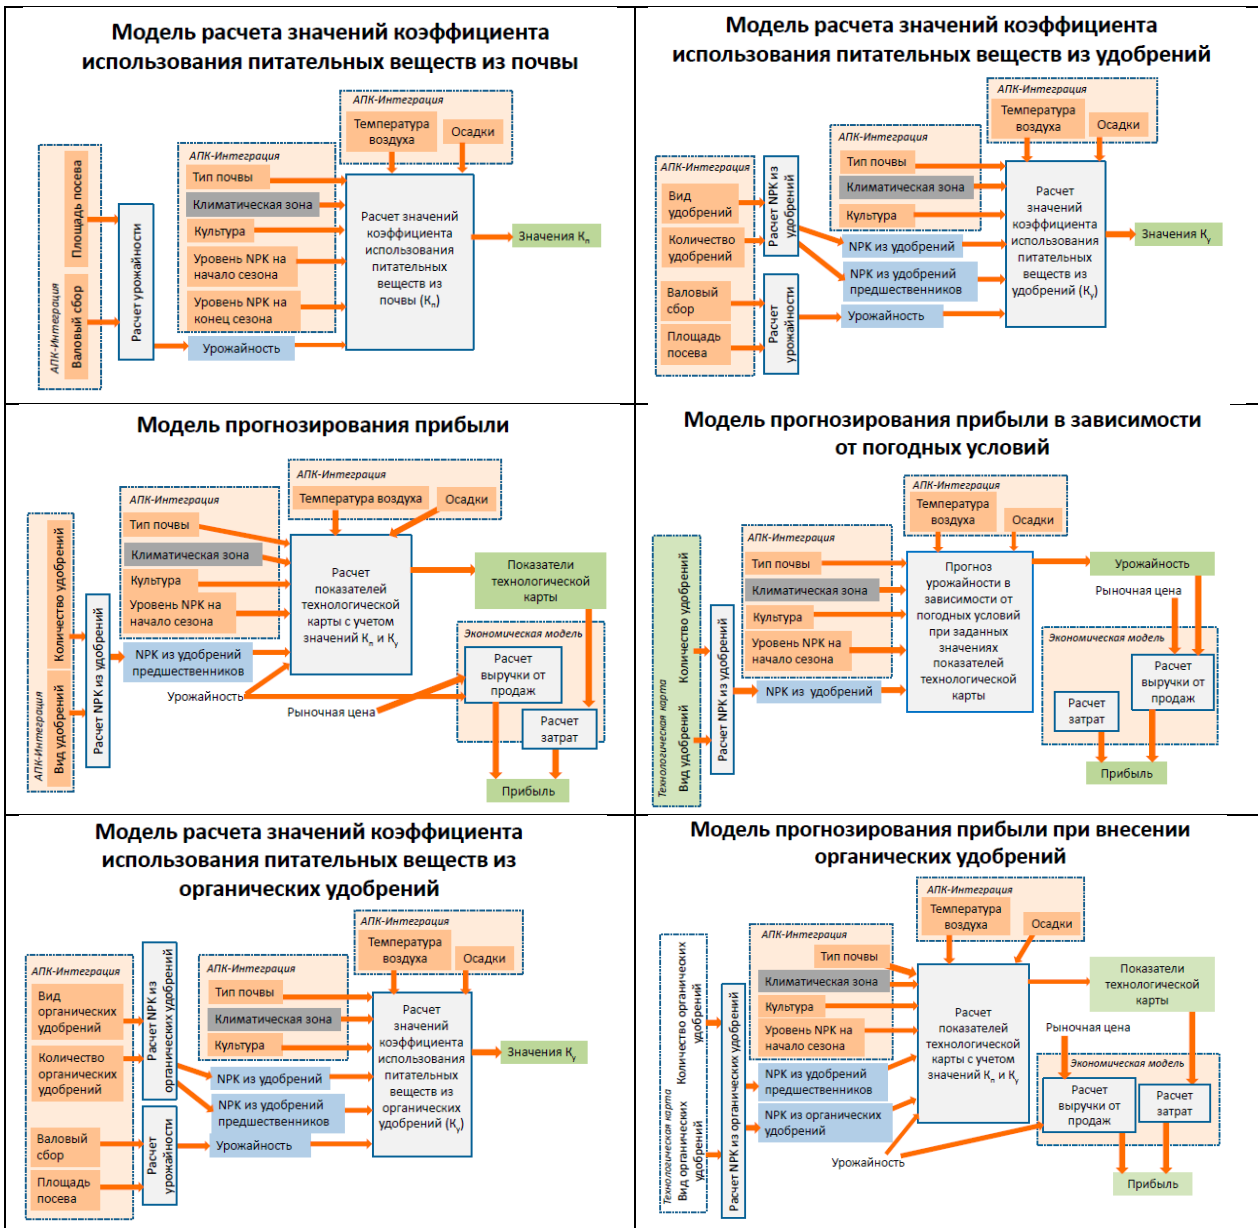


Рис. 9. Примеры функционально-аналитических схем для поддержки принятия решений по управлению производственным процессом

## Заключение

Был предложен концептуальный подход к созданию инновационных систем поддержки управления производственными процессами сельхозпредприятий. Разработаны методы создания предиктивных идентификационных моделей для поддержки управления отдельными технологическими процессами, в частности, дифференцированным внесением удобрений, основанные на интеллектуальном анализе данных.

Наличие базы данных с информацией об урожае, выращенном в разные периоды в различных климатических зонах на почвах с различными свойствами, с учетом содержания элементов питания в почве и количества вносимых удобрений, позволяет получить эффективный прогноз урожайности. Проработка функциональных схем производственных процессов и информационных потоков позволяет предложить методы поддержки принятия ре-

шений по управлению производственными процессами сельхозпредприятий посредством интеллектуальных предиктивных моделей для различных показателей.

## Литература

1. Vapnik V. Estimation of Dependences Based on Empirical Data. Springer, 2006.
2. A. Chervonenkis Reconstruction of conditional distribution field based on empirical data. In the book Soft Computing Systems (Design, Management and Application). Edited by Ajith Abraham, Javier Ruiz-del-Solar and Mario Koppen). IOS Press, 2002. Pp.462-469.
3. Bakhtadze, Natalia; Lototsky, Vladimir; Vlasov, Stanislav; Sakrutina, Ekaterina, Associative Search and Wavelet Analysis Techniques in System Identification // IFAC Proceedings Volumes. Series Title: System Identification, 2012. Vol. 16 | Part 1. Pp.1227-1232. ISSN: 1474-6670. ISBN: 978-3-902823-06-9.
4. Bakhtadze N., Pyatetsky V, Lototsky V. Knowledge-Based Models of Nonlinear Systems Based on Inductive Learning / New Frontiers in Information and Production Systems Modeling and Analysis: Incentive Mechanisms, Competence Management, Knowledge-based Production. Heidelberg: Springer, 2016. Pp. 85-104.
5. Bakhtadze N., Pyatetsky V, Sakrutina E. Predicting Oil Product Properties with Intelligent Soft Sensors // IFAC-PapersOnLine. 2017. Vol. 50, N1. Pp. 14632–14637.
6. Bakhtadze, N., Maximov, E., Donchan, D., Maximova, N.E., Kozlovskaya, L. Innovation and knowledge management in precision farming // Proceedings of the 12th IADIS International Conference on Information Systems (Utrecht, Netherlands, 2019). Utrecht, Netherlands: International Association for Development of the Information Society, 2019. Pp. 265-270.
7. Артюшин А.М., Державин Л.М. Краткий справочник по удобрениям. М.: Колос, 1984. – 208 с.
8. Смирнов П.М., Муравин Э.А. Агрохимия. М.: Колос, 1977. 240 с.
9. Губанов Я.В., Иванов Н.Н. Озимая пшеница. М.: Агропромиздат, 1988. 303 с.
10. Просяникова О.И., Просяников В.И. Коэффициенты использования фосфора и калия из почвы зерновыми культурами // Агрохимический вестник. 2009. № 6. С. 7-8.
11. Пигоров И.Я., Семькин В.А. Содержание элементов питания в растениях и вынос их с урожаем озимой пшеницы // Современные проблемы науки и образования. 2007. № 2. С. 38-40.
12. Радикорская В.А., Фокин С.А. Влияние доз и соотношение минеральных удобрений на рост и развитие яровой пшеницы // Дальневосточный аграрный вестник. 2010. № 1 (13). С. 14-17.
13. Варламов В.А. и др. Вынос NPK пшеницей и ячменем на дерново-подзолистой тяжелосуглинистой почве ЦРНЗ РФ // Плодородие. 2012. № 2. С. 12-14
14. Зинковская Т.С. Коэффициент использования азота удобрений озимой рожью и ячменем на дерново-подзолистой осушаемой почве // Международный научно-исследовательский журнал. 2015. № 3 (34), Часть 2. С. 20-21
15. Дзюин Г.П., Дзюин А.Г. Коэффициенты использования азота, фосфора и калия из минеральных удобрений, навоза и почвы культурами севооборота // Международный журнал экспериментального образования. 2016. № 5. С. 83-90.

**Бахтадзе Наталья Николаевна.** Заведующий лабораторией Института проблем управления РАН, Москва. Доктор технических наук, профессор. Количество печатных работ: более 250. Область научных интересов: идентификация систем управления, адаптивное управление, интеллектуальный анализ данных, управление знаниями, управление производственными процессами. E-mail: sung7@yandex.ru

**Максимов Евгений Михайлович.** Старший научный сотрудник Института проблем управления РАН. Количество печатных работ: более 100 (в т. ч. 2 монографии). Область научных интересов: идентификация систем управления, адаптивное управление, интеллектуальный анализ данных, управление знаниями, управление производственными процессами. E-mail: maxfone@yandex.ru

**Максимова Наталья Евгеньевна.** Ведущий инженер Института проблем управления РАН. Кандидат технических наук. Количество печатных работ: 20. Область научных интересов: идентификация систем управления, адаптивное управление, интеллектуальный анализ данных, управление знаниями, управление производственными процессами. E-mail: natalya\_maximova@mail.ru

**Дончан Данила Михайлович.** Научный сотрудник Института проблем управления РАН. Количество печатных работ: 15. Область научных интересов: идентификация систем управления, адаптивное управление, интеллектуальный анализ данных, управление знаниями, управление производственными процессами. E-mail: donchan@yandex.ru

**Кузнецов Денис Сергеевич.** Ученый секретарь кафедры бизнес-информатики НИТУ МИСиС. Количество печатных работ: 3. Область научных интересов: идентификация систем управления, управление бизнес-процессами, управление ресурсами производственных процессов. E-mail: sined170495@yandex.ru

**Захаров Эдуард Александрович.** Московский физико-технический институт. Научный сотрудник. Количество печатных работ: 4. Область научных интересов: теория управления, идентификация, компьютерное моделирование. E-mail: eddyzaharov@gmail.com

## Intelligent Management Systems for Digital Farming. Part 1

N. Bakhtadze<sup>1</sup>, E. Maximov<sup>1</sup>, N. Maximova<sup>1</sup>, D. Donchan<sup>1</sup>, D. Kuznetsov<sup>II</sup>, E. Zakharov<sup>III</sup>

<sup>1</sup>V.A. Trapeznikov Institute of Control Science of Russian Academy of Science, Moscow, Russia

<sup>II</sup>National University of Science and Technologies NUST MISIS

<sup>III</sup>Moscow Institute of Physics and Technology, Moscow, Russia

**Abstract.** The article presents an approach to the creation of information systems for digital farming, which allows more rational planning of land use, the use of fertilizers and fuel based on information technologies and intelligent forecasting models, which reduces the cost of production and increases the efficiency of agricultural production. In addition, a long-term agronomic and environmental effect can be achieved due to more gentle tillage and a decrease in the use of nitrogen fertilizers. The principles of creating a knowledge base and constructing models of grain yield depending on the regime of applying fertilizers based on intelligent identification algorithms, as well as models for predicting prices for digital agriculture products, have been developed.

**Keywords:** digital farming, soft sensors, predictive models, knowledge management.

DOI 10.14357/20718632200208

## References

1. Vapnik V. Estimation of Dependences Based on Empirical Data. Springer, 2006.
2. A. Chervonenkis Reconstruction of conditional distribution field based on empirical data. In the book *Soft Computing Systems (Design, Management and Application)*. Edited by Ajith Abraham, Javier Ruiz-del-Solar and Mario Koppen). IOS Press, 2002. Pp.462-469.
3. Bakhtadze, Natalia; Lototsky, Vladimir; Vlasov, Stanislav; Sakrutina, Ekaterina, *Associative Search and Wavelet Analysis Techniques in System Identification // IFAC Proceedings Volumes. Series Title: System Identification, 2012. Vol. 16 | Part 1. Pp.1227-1232. ISSN: 1474-6670. ISBN: 978-3-902823-06-9.*
4. Bakhtadze N., Pyatetsky V, Lototsky V. Knowledge-Based Models of Nonlinear Systems Based on Inductive Learning / *New Frontiers in Information and Production Systems Modeling and Analysis: Incentive Mechanisms, Competence Management, Knowledge-based Production*. Heidelberg: Springer, 2016. Pp. 85-104.
5. Bakhtadze N., Pyatetsky V, Sakrutina E. Predicting Oil Product Properties with Intelligent Soft Sensors // *IFAC-PapersOnLine*. 2017. Vol. 50, N1. Pp. 14632–14637.
6. Bakhtadze, N., Maximov, E., Donchan, D., Maximova, N.E., Kozlovskaya, L. *INNOVATION AND KNOWLEDGE MANAGEMENT IN PRECISION FARMING // Proceedings of the 12th IADIS International Conference on Information Systems (Utrecht, Netherlands, 2019)*. Utrecht, Netherlands: International Association for Development of the Information Society, 2019. Pp. 265-270.
7. Artyushin A.M., Derzhavin L.M. A quick reference to fertilizers. M.: Kolos, 1984. - 208 p.
8. Smirnov P.M., Muravin E.A. *Agrochemistry*. M.: Kolos, 1977. 240 s.
9. Gubanov Y. V., Ivanov N. N. Winter wheat. M.: Agropromizdat, 1988. 330 s.
10. Prosyannikova O.I., Prosyannikov V.I. Coefficients of use of phosphorus and potassium from the soil by grain crops // *Agrochemical Bulletin*. 2009. No. 6. S. 7-8.
11. Pigorev I.Ya., Semykin V.A. The content of nutrients in plants and their removal with a harvest of winter wheat // *Modern problems of science and education*. 2007. No. 2. P. 38-40.
12. Radikorskaya V.A., Fokin S.A. The effect of doses and the ratio of mineral fertilizers on the growth and development of spring wheat // *Far Eastern Agrarian Bulletin*. 2010. No. 1 (13). S. 14-17.
13. Варламов В.А. и др. Вынос NPK пшеницей и ячменем на дерново-подзолистой тяжелосуглинистой почве ЦРНЗ РФ // *Плодородие*. 2012. № 2. С. 12-14
14. Zinkovskaya T.S. The coefficient of nitrogen utilization of fertilizers by winter rye and barley on sod-podzolic drained soil // *International Scientific Journal*. 2015. No 3 (34), Part 2. P. 20-21
15. Djuin G.P., Djuin A.G. The utilization rates of nitrogen, phosphorus and potassium from mineral fertilizers, manure and soil by crop rotation crops // *International Journal of Experimental Education*. 2016. No. 5. P. 83-90.

**Bakhtadze N. N.** Professor, Head of Identification laboratory of V.A. Trapeznikov Institute of Control Science of Russian Academy of Science, 65 Profsoyuznaya str., Moscow, Russia. In 1979, he graduated from the Moscow State Institute of Electronics and Mathematics. Author of over 250 scientific papers. Research interests: control systems identification, adaptive control, data mining, knowledge management, production process control.

**Maximov E.M.** PhD, Senior Researcher of V.A. Trapeznikov Institute of Control Science of Russian Academy of Science, 65 Profsoyuznaya str., Moscow, Russia. In 1975, he graduated from the Moscow State Institute of Electronics and Mathematics. Author of over 100 scientific papers. Research interests: control systems identification, adaptive control, data mining, knowledge management, production process control.

**Maximova N.E.** PhD, chief engineer of V.A. Trapeznikov Institute of Control Science of Russian Academy of Science, 65 Profsoyuznaya str., Moscow, Russia. In 2005, she graduated from the Moscow State Institute of Electronics and Mathematics. Author of 20 scientific papers. Research interests: control systems identification, adaptive control, data mining, knowledge management, production process control.

**Donchan D.E.** Research assistant of V.A. Trapeznikov Institute of Control Science of Russian Academy of Science, 65 Profsoyuznaya str., Moscow, Russia.

**Kuznetsov D.S.** Scientific Secretary of the Department of Business Informatics National University of Science and Technologies NUST MISIS, Moscow, Leninsky Prospect, 4. In 2016, he graduated from NITU MISiS. The author of 3 scientific papers. Research interests: control system identification, business process management, resource management of production processes.

**Zakharov E. A.** Moscow Institute of Physics and Technology, Moscow, Russia. Researcher. Number of publications: 4. Research interests: system control theory, identification, computer modeling.