

Методы идентификации в управлении технологическими процессами

Бахтадзе Наталья Николаевна

**Институт проблем управления
имени В.А. Трапезникова РАН**

Москва, 2026



Термин «идентификация»
предложил в 1956 г. Лотфи Заде

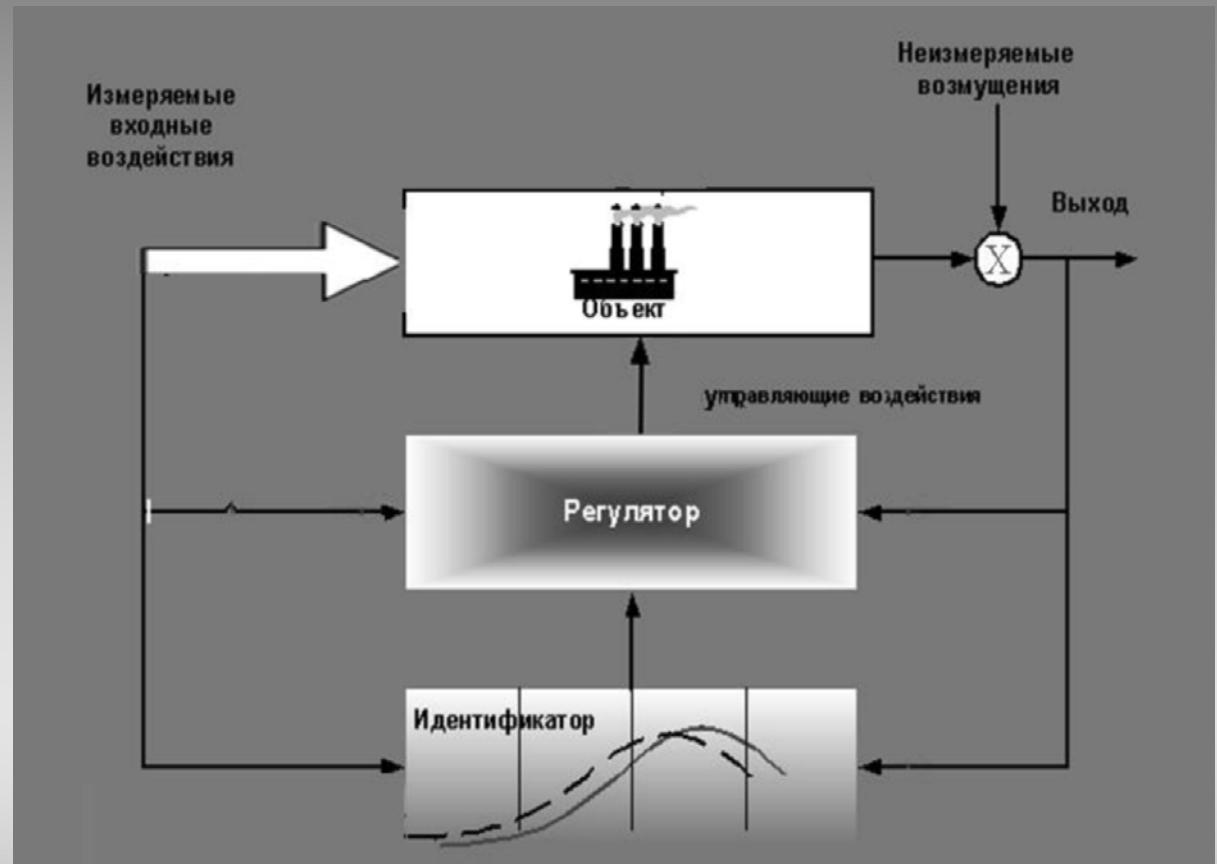
ZADEH, L. On the identification problem // IRE Tranc. of Circuit Theory, CT-3. – 1956. – P. 277-281.

Идентификация - построение математической модели объекта/системы посредством **анализа данных функционирования** (реального либо экспериментального)

Альтернатива т.н. «строгим» моделям имитационного моделирования, в основе которых лежат известные законы (физические, химические, и т.д.) либо инженерные и технологические расчеты

Цели идентификации

- Анализ свойств объекта,
- Решение задач управления



Понятие **адекватности модели** непосредственно связано с выполнением определенных требований **к управлению**.



*«Идентификация систем - это
интерфейс между реальным миром
приложений и - математическим
миром теории управления и
модельных абстракций».*

Л.Льюнг



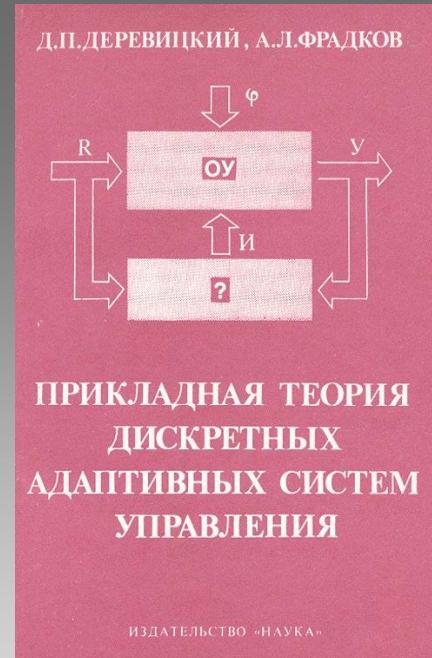
«Идентификация вдохнула в проблему построения модели новую жизнь, выдвинула требования, которые непосредственно вытекали из задачи управления».

Н.С. Райбман

Два фундаментальных подхода к синтезу адаптивных систем.

1. Управление с эталонной моделью (Model-Reference)

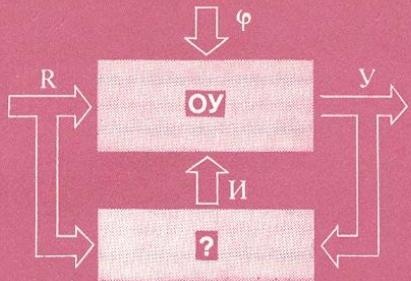
Наличие в системе управления **явной эталонной модели**, которая **задает требуемое качество переходных процессов и желаемое поведение объекта**.



ПРИКЛАДНАЯ ТЕОРИЯ
ДИСКРЕТНЫХ
АДАПТИВНЫХ СИСТЕМ
УПРАВЛЕНИЯ

ИЗДАТЕЛЬСТВО «НАУКА»

- Принцип:** Цель управления - минимизация рассогласования (ошибки) между выходами реального объекта и эталонной модели.
- Механизм:** Алгоритмы адаптации (например, метод скоростного градиента, разработанный Фрадковым) подстраивают параметры регулятора так, чтобы динамика объекта стремилась к динамике модели.
- Разновидность:** метод с **неявной эталонной моделью**, где желаемые свойства системы задаются не отдельным блоком, а через структуру уравнений или целевой функционал.



ПРИКЛАДНАЯ ТЕОРИЯ
ДИСКРЕТНЫХ
АДАПТИВНЫХ СИСТЕМ
УПРАВЛЕНИЯ

ИЗДАТЕЛЬСТВО «НАУКА»

Два фундаментальных подхода к синтезу адаптивных систем

2. Управление без модели (Model-Free / Непрямое управление)

В терминологии адаптивного управления 1970–80-х годов под этим часто понимались системы, **не использующие явную динамическую модель «идеального» поведения для формирования ошибки, а использующие текущие данные об объекте.**

- **Идентификационный подход:** Система сначала (или параллельно) оценивает текущие параметры объекта (**строит его модель «на лету»**), а затем синтезирует управление на основе этой оценки.
- **Прямая адаптация:** Регулятор настраивается непосредственно по критерию качества (например, минимизация дисперсии ошибки), без промежуточного шага идентификации параметров объекта.

Методы идентификации:

- **активные и пассивные**

Активные методы используют тестовые воздействия, подаваемые на вход объекта/системы – специально сформированные сигналы (детерминированные либо стохастические).

Пассивные методы основаны на обработке статистической информации реального функционирования объекта.

- **оперативные и ретроспективные**

- по признаку использования только оперативной
- либо еще и ретроспективной информации,
- а также по темпу обработки этой информации.

Классы моделей и методов идентификации

Идентификационные модели:

- статические и динамические;
- линейные и нелинейные;
- детерминированные и стохастические;
- стационарные и нестационарные;
- дискретные и непрерывные;
- сосредоточенные и распределенные;
- в пространстве «вход-выход» и в пространстве состояний;
- параметрические и непараметрические

Идентификация системы управления как обратная задача динамики

Построение оператора с известной структурой, адекватно и удовлетворительно описывающего реальное функционирование системы в смысле выбранного критерия можно интерпретировать как **обратную задачу динамики**.

Решение может

- не существовать,
- быть не единственным,
- быть неустойчивым по отношению к погрешностям измерения исходных данных. Такие задачи относятся к классу **некорректно поставленных**.

Эволюция методов идентификации

Идентификация как обратная задача динамики



Корректно поставленная задача в математике — прикладная задача, математическое решение которой существует, единственно и устойчиво.

Жак Адамар

Для решения некорректных задач, в частности, вырожденных и плохо обусловленных СЛАУ, был предложен **метод регуляризации**. В его основе лежит учет дополнительной априорной информации.

Для получения единственного устойчивого приближенного решения СЛАУ $Ax=b$ используются различные методы регуляризации.
Минимум **функционала Тихонова**:

$$\Omega(x, \lambda) = |Ax - b|^2 + \lambda|x - x_0|^2$$

Эволюция методов идентификации

Метод наименьших квадратов



А.М. Лежандр К.Ф. Гаусс

Формулировки МНК были предложены в первом десятилетии XIX века практически одновременно А.М. Лежандром, К.Ф. Гауссом.

МНК состоит в замене значений измерений т.н. «модельными» значениями, которые находятся из условия минимума квадратичной функции разности модельных значений и реальных измерений («**невязки**»).

П-С. Лаплас связал метод с теорией вероятностей

Работы А. А. Маркова в начале XX века позволили включить МНК в теорию оценивания



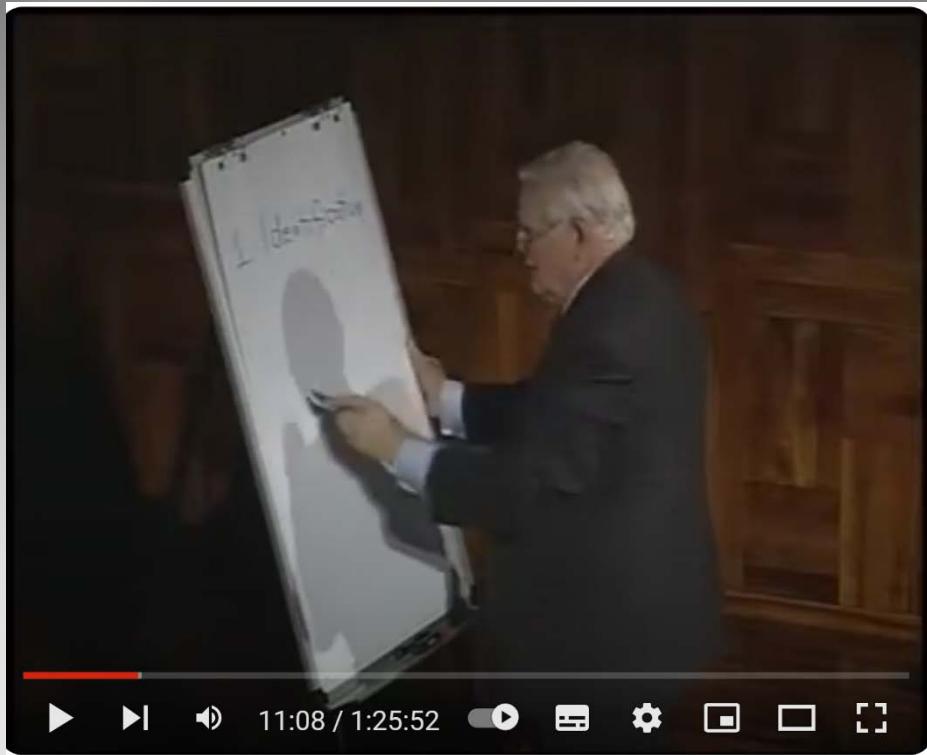
Идентификация в 20-х – 50-х гг. XX века

изучение реакций систем на определенные управляющие (тестовые) воздействия (ступенчатое, гармоническое, и т.д.).

ÅSTRÖM, KARL JOHAN; EYKHOFF, PIETER. *System Identification : A Survey* // Automatica, 1971. – Р. 123-162.

Практическое применение этих методов было ограничено, поскольку предполагало удовлетворение требований линейности, стационарности, нормальности распределений. Скалярный случай.

Эволюция методов идентификации



Пространство состояний 1960

Рудольф Калман
**описание системы управления
в пространстве состояний и
основы оптимальной
фильтрации**

Работы Р. Калмана и Р. Бьюси в 1960-х г. легли в основу методов
теории рекуррентного (последовательного) оценивания.



Идентификация систем как статистическая теория

Неполнота и неточность априорной информации, необходимость учета реальных условий функционирования и изменений во времени как характеристик самих объектов, так и условий их функционирования вызвали потребность в создании новых принципов и методов построения моделей объектов управления для решения задач анализа и синтеза

Н.С. Райбман

Эволюция методов идентификации

Методы максимального правдоподобия

1965 К. Острём: методы идентификации систем управления, основанные на минимизации критерия, зависящего от параметров модели – **методы максимального правдоподобия**.

К.Й. Острем, Н.С. Райбман. Введение в стохастическую теорию управления. М.: Мир, 1973.

К.Й. Острем. Лунд, Швеция, 2019



Эволюция методов идентификации

- **Метод максимального правдоподобия (ML)**, предложенный Гауссом и Лапласом, а затем популяризованный Фишером в начале XIX века - максимизация плотности вероятности наблюдений. Определяются параметры, при которых данные наиболее вероятны

– **Метод апостериорного максимума (Maximum A Posteriori, MAP)** - Метод максимума апостериорной вероятности — это байесовский метод оценки неизвестной величины (параметров модели) на основе имеющихся данных и предварительных знаний.

В отличие от метода максимального правдоподобия, который ищет параметры, при которых данные наиболее вероятны, MAP учитывает априорную вероятность параметров.

$$P(\theta|X) = \frac{P(X|\theta)P(\theta)}{P(X)}$$

– **Метод оценки минимальной среднеквадратической ошибки (MMSE).**

Определяются параметры, которые максимизируют вероятность получения имеющихся данных. Если ошибки (невязки) распределены нормально, то **максимизация функции правдоподобия становится эквивалентна минимизации суммы квадратов невязок** (метод наименьших квадратов).¹⁸

Эволюция методов идентификации

Методы максимального правдоподобия

Преимущества над МНК

- Методы идентификации, использующие квадратичный критерий качества **чувствительны к отклонениям закона распределения от нормального.**
- МНК **утрачивает эффективность в условиях различных выбросов, грубых ошибок, негауссовских помех с тяжелыми хвостами.**
- Оценки максимального правдоподобия, вообще говоря, могут быть смешёнными, но **являются состоятельными, асимптотически эффективными и асимптотически нормальными.**

ММП дает хорошие результаты, если к анализу данных применяется **байесовский подход** (при котором вероятность интерпретируется как мера неопределенности знаний об исследуемом объекте).

Байесовская оценка решения — это статистическая оценка, минимизирующая апостериорное математическое ожидание функции потерь

Эволюция методов идентификации 70-е – 80-е

Рекуррентные алгоритмы идентификации

Методы были направлены на получение **описания максимально «точного» описания функционирования** системы.

Ставится вопрос о **сходимости к «точным параметрам»** и исследуются связанные с ним

вопросы **идентифицируемости систем и статистические свойства оценок.**

Эволюция методов идентификации 70-е – 80-е

Адаптивные алгоритмы идентификации, использующие представление сигналов в частотной и временной областях

Градиентные методы

оценки параметров математических моделей систем на основе минимизации целевой функции (например, среднеквадратичного отклонения). Параметры корректируются в направлении, противоположном вектору градиента функции потерь.

Алгоритмы стохастической аппроксимации

расширение градиентных методов для случая, когда данные поступают с помехами или случайными искажениями.

Алгоритм Роббинса-Монро: позволяет находить корни уравнений или экстремумы функций при наличии случайных ошибок измерения.

Стохастический градиентный спуск (SGD): частный случай стохастической аппроксимации. Применяется для обучения нейросетей и идентификации динамических объектов в реальном времени.

Актуальные задачи

- Статистические свойства оценок
- Идентифицируемость систем
- Исследование смещенности оценок и ошибки дисперсии для оценивания передаточных функций объектов
- Идентификация нелинейных динамических систем, представляемых функциональным рядом Вольтерра
- Структурная идентификация - задачи выбора операторов или систем уравнений, описывающих процессы в исследуемой системе

Идентификация как проблема синтеза

Методы регуляризации в задачах нахождения оценки весовой функции линейных и нелинейных стохастических систем



Эволюция методов идентификации

Идентификация: 90-е

Методы робастной идентификации

Эффективны при наличии выбросов в данных или небольших ошибок в гипотезах.

Предназначены для построения математических моделей систем **в условиях неопределенности, когда исходные данные содержат отклонения от принятых статистических предположений** (например, наличие «выбросов» или тяжелых хвостов распределения)

Эволюция методов идентификации

Идентификация: 80-е - 90-е +

Методы робастной идентификации

М-оценки (Maximum likelihood-type estimators)- модифицированный метод наименьших квадратов (МНК), функция минимизации заменяется на более устойчивую к выбросам, уменьшающую вес резко отклоняющихся наблюдений.

Использование устойчивых целевых функций - Замена квадратичной функции потерь на функции, менее чувствительные к выбросам (например, функция Хьюбера, функция Тьюки), линейные или постоянные.

Алгоритмы полиэдрального оценивания используют определенное количество неравенств для ограничения области возможных значений параметров при наличии ограниченных помех.

Нейросетевые методы используют нейронные сети для идентификации объектов в условиях высокой неопределенности и помех.

Робастная идентификация по малому числу наблюдений - методы, направленные на построение моделей, устойчивых к выбросам даже при ограниченном наборе данных.

Эволюция методов идентификации

Идентификация: 60-е - 90-е ИПУ РАН

- Алгоритмы **условного прогнозирования** выходной реакции объектов управления. Методы динамической оптимизации технологических процессов – **И.И. Перельман.**
- Исследование **идентифицируемости** как задачи **однозначной восстанавливаемости параметрического описания.**
Б.Н. Петров: **условия параметрической идентифицируемости** объектов управления в замкнутых автоматических системах.
- Методы идентификации объектов **с распределенными параметрами.**

Эволюция методов идентификации

Идентификация: 70-е - 90-е ИПУ РАН лаборатория идентификации

- **Адаптивные алгоритмы.** Влияние корреляции в помехах измерений на структуру оптимальных алгоритмов, а также погрешностей вычислений - на сходимость алгоритмов.
- **Дисперсионная теория статистически оптимальных систем,** в рамках которой характеристики оптимальной системы находятся по сложному критерию, представляющему собой функционал от дисперсионных функций различных типов.
- Методы идентификации **многомерных, нелинейных, нестационарных объектов.**

Эволюция методов идентификации

Идентификация: 70-е - 90-е ИПУ РАН лаборатория идентификации

- Методы, основанные на идеи **кусочной аппроксимации**.

Фазовое пространство входного сигнала разбивается на несколько непересекающихся областей таким образом, что внутри каждой из этих областей условная дисперсия шума относительно входного сигнала приближенно постоянна.

- методы **определения структуры**.
- **модели объектов с распределенными параметрами**.

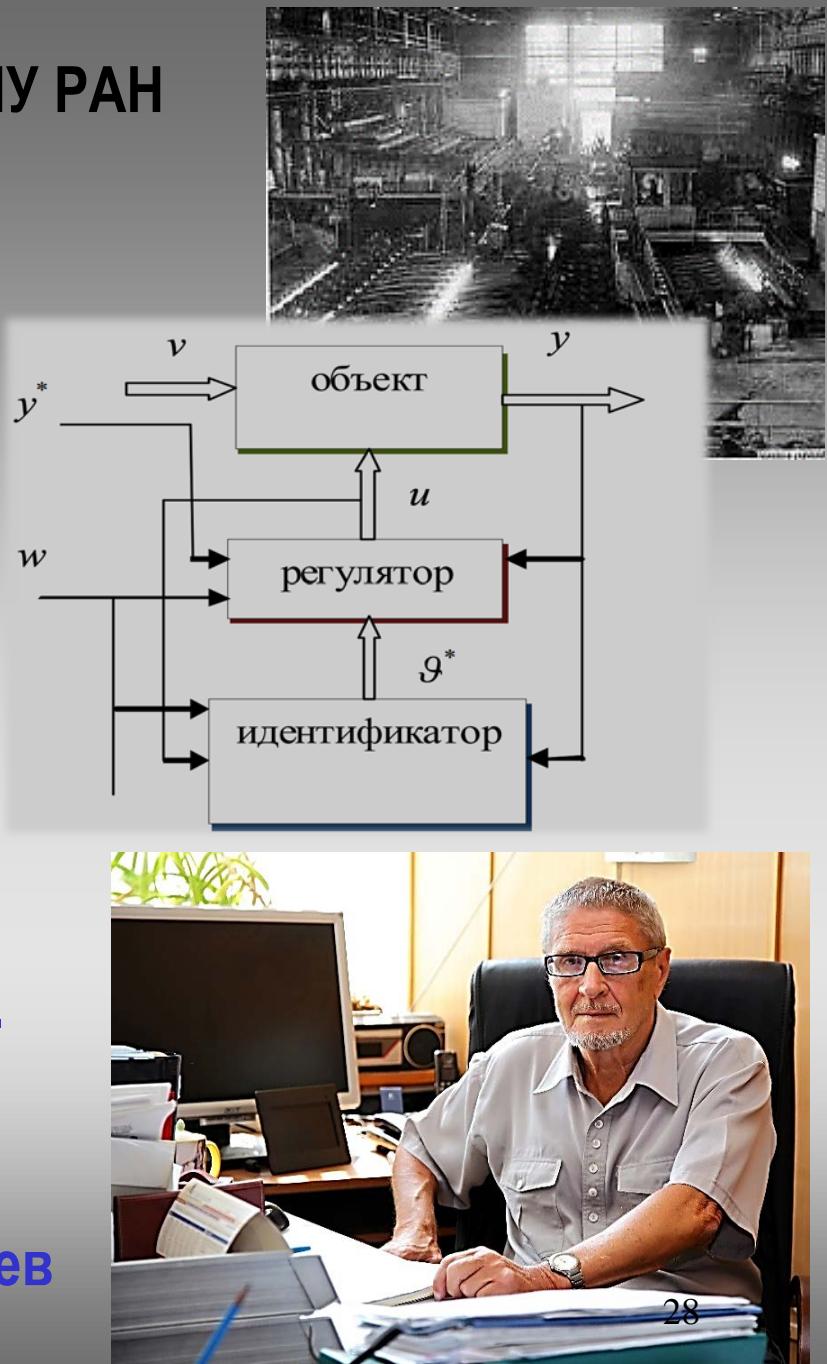
Идентификация: 70-е - 90-е ИПУ РАН лаборатория идентификации

Адаптивные системы с
идентификатором в цепи обратной
связи

Система управления трубопрокатным
станом 160 на Первоуральском
Новотрубным заводом (ПНТЗ)

Государственная премия СССР 1976 г.

В.М. Чадеев



Многочисленные приложения

Система автоматизации производства бора -
Дальнегорск.

Устькаменогорск: на Титаномагниевом
комбинате создавалась система управления для
изготовления титановой губки.

Работы в области производства магния и др.



Адаптивные системы с идентификатором
для управления точностью горячей прокатки
бесшовных труб работали **практически на**
всех трубных заводах страны.



Эволюция методов идентификации

Идентификация: 70-е - 90-е ИПУ РАН лаборатория идентификации

Идентификация объекта в замкнутых системах в условиях шумов и параметрических возмущений

- Проблема сходимости оценок в замкнутом контуре - при коррелированности возмущений на выходе объекта и в сигнале управления.
- Алгоритмы получения состоятельных оценок параметров объекта в замкнутом контуре.

А.Л. Бунич



Эволюция методов идентификации

Идентификация: 70-е - 90-е



1986 г. Я.З. Цыпкин: **информационная теория идентификации**, определяющая алгоритмы идентификации, оптимальные для различных классов объектов, для чего вводится понятие **оптимальных на классе функций потерь**.

Асимптотически оптимальные алгоритмы идентификации - алгоритмы, обладающие максимальной скоростью сходимости при известной плотности распределения помехи.

Идентификация: 90-е +



Идентификация в условиях неопределенности

Методы на основе **интервального анализа**, основанного на **методе эллипсоидов** - для объектов с интервальной неопределенностью.

Б.Т. Поляк

При ограниченных возмущениях в системе и в отсутствии информации о законах их распределений - **метод гарантированного оценивания**.

Для оценивания параметров линейных стационарных систем в условиях неопределенности - **техника линейных матричных неравенств**.



П.С. Щербаков³²



Идентификация: 90-е +

Идентификация в условиях неопределенности

При **статистическом описании неопределенности** значения функционалов от эмпирического распределения с увеличением объема выборки наблюдений сближаются с соответствующими «теоретическими», что позволяет получать **состоятельные оценки** характеристик объекта.

Методы теории робастного оценивания

Основная идея робастного оценивания — это построение статистических процедур, устойчивых к возможным отклонениям от принятых вероятностных моделей распределений данных.

Идентификация: 90-е +

Методы прямой оптимизации весов для нелинейных задач оценивания функции регрессии и идентификации авторегрессионных систем при непараметрической неопределенности



Рандомизированные алгоритмы. Рандомизация: добавление в алгоритм дополнительных, случайных, но контролируемых возмущений.

Идентификация: 90-е +

Метод конечно-частотной идентификации

(активная идентификация). **Пробный сигнал** представляет собой сумму гармоник, число которых не превышает величину вектора состояния объекта. Амплитуды и частоты этого сигнала в значительной мере влияют на точность идентификации.



Разработаны алгоритмы ([А.Г. Александров](#)), которые обеспечивают малое влияние испытательного сигнала на выход объекта, по сравнению с влиянием возмущений и помех

Идентификация: 90-е +

Идентификация **нелинейных** объектов

Статические:

- **методы линеаризации:** гармонической, статистической, малых приращений – для объектов с гладкими характеристиками и для случаев небольших отклонений и возмущений относительно номинальных режимов;
- **основанные на аппроксимации модели объекта,** если структура модели точно не известна. Полиномы Чебышева, Эрмита, Лагерра.

Динамические:

методы матричных операторов для аппроксимации нелинейных динамических объектов.

Строются функциональные полиномы, ортогональные для заданного класса входных сигналов. Процесс идентификации заключается в **определении ядер на основе статистической обработки данных наблюдений.**

Ряды Вольтерры, Гаммерштейна, Винера, непрерывных и дискретных полиномов Колмогорова – Габора.

Представление ортогональных функциональных рядов в частотной области позволяет найти оптимальное решение в явном виде. Оценки в частотной области. Алгоритм быстрого преобразования Фурье.

Идентификация сегодня

Идентификация **нелинейных** объектов

Рассматриваются классы моделей:

- **линейные модели с изменяющимися параметрами (LPV),**
- **нелинейные (NL).**

Модели LPV применяются для представления:

- линейных изменяющихся во времени (LTV) систем, динамика которых описывается функцией измеримого изменяющегося во времени вектора параметров **$p(t)$, называемого переменной планирования.**
- **систем, линеаризованных вдоль траектории $p(t)$.**

Идентификация сегодня

Идентификация **нелинейных** объектов

В LPV-модели динамика описывается линейными уравнениями состояния, но матрицы системы не являются постоянными. Они зависят от некоторого вектора внешних параметров который $\theta(t)$ изменяется во времени:

$$\begin{aligned}\dot{x}(t) &= A(\theta(t))x(t) + B(\theta(t))u(t) \\ y(t) &= C(\theta(t))x(t) + D(\theta(t))u(t)\end{aligned}$$

- в LTI-системах параметры фиксированы.
 - в LPV-системах параметры измеряются в реальном времени, но их будущее значение заранее неизвестно.
 - в нелинейных системах динамика зависит от переменных состояния $x(t)$
-
- Апроксимация нелинейности.
 - LPV-подход позволяет проектировать регуляторы, которые автоматически подстраиваются под текущий режим работы системы, обеспечивая стабильность во всем рабочем диапазоне.
 - Использование линейных методов.

Идентификация сегодня

Идентификация нелинейных объектов

Модели нелинейных объектов (NL)

- модификации моделей Винера, Гаммерштейна, Винера-Гаммерштейна,
- конечномерные модели Вольтерра с дискретным временем - **усеченные разложения в ряд Вольтерра**, которые позволяют аппроксимировать любую нелинейную систему с затухающей памятью с приемлемой точностью.

$$y(t) = h_0 + \int h_1(\tau)x(t - \tau)d\tau + \iint h_2(\tau_1, \tau_2)x(t - \tau_1)x(t - \tau_2)d\tau_1 d\tau_2 + \dots$$

1. h_0 – постоянная составляющая.
2. $h_1(\tau)$ – линейное ядро (обычная импульсная характеристика).
3. $h_n(\tau_1, \dots, \tau_n)$ – ядра Вольтерра n -го порядка, описывающие нелинейные свойства системы.

- **линейные модели с конечной импульсной характеристикой (FIR)** с гарантированной стабильностью в смысле ограниченного входа и ограниченного выхода (BIBO).

Идентификация нестационарных объектов

Аппроксимационные методы: осуществляется **переход от бесконечномерного к конечномерному параметрическому пространству**, а затем используются методы идентификации для стационарных объектов.

Аппроксимация неизвестных переменных параметров:

- **полиномами** конечной степени на всем интервале:
 - Использование **разложения входа и выхода объекта в ряды по экспоненциальным функциям**: позволяет редуцировать задачу к линейной.
 - Исходное уравнение с полиномиальными коэффициентами с помощью разложения входа - выхода **в ряды по блочно-импульсным функциям** преобразуется в систему линейных алгебраических уравнений,
- **ортогональными функциями**
метод оценки коэффициентов в разложении переменных параметров по ортогональному базису в пространстве функций, суммируемых с квадратом, с использованием рекуррентного МНК.

Прямые методы (не производится предварительная редукция к конечномерному параметрическому пространству):

- **методы на основе рекуррентных алгоритмов,**
- **методы гарантированного оценивания и оптимального сглаживания,**
- **спектральные методы и нейронные сети.**

Идентификация: 90-е +

Непараметрические методы

Методы на основе оценивания: **переходных и импульсных переходных характеристик, частотных и спектральных характеристик.**

Информационно-теоретические подходы к структурной, параметрической и непараметрической идентификации стохастических систем – применение согласованных мер зависимости случайных величин и мер расходимости вероятностных распределений.

Идентификация сегодня

Методы идентификации стохастических систем на основе теоретико-информационных мер зависимости

- Алгоритм преобразования состоятельной меры зависимости в состоятельную меру зависимости по Ренни (то есть удовлетворяющую как минимум всем аксиомам Ренни за исключением аксиомы об инвариантности взаимнооднозначных преобразований случайных величин).
- Обобщение аксиоматики Ренни на случай множественной зависимости.
- Метод выбора входных и выходных переменных модели на основе состоятельных по Ренни мер зависимости и меры гетерогенности (то есть неравномерности вклада переменных в модель).
- Построение мер зависимости по Ренни на основе дивергенций Ренни и Цаллиса.

К.Р. Чернышев



Идентификация объектов с распределенными параметрами

Динамика СРП описывается дифференциальными уравнениями в частных производных, интегральными и интегро-дифференциальными уравнениями.

1. Методы сведения моделей СРП к моделям систем с сосредоточенными параметрами
2. Оптимизация

Идентификация объектов с распределенными параметрами

Динамика СРП описывается дифференциальными уравнениями в частных производных, интегральными и интегро-дифференциальными уравнениями.

1. Методы сведения моделей СРП к моделям систем с сосредоточенными параметрами

- метод Галеркина,
- метод характеристик,
- метод конечных элементов,
- метод моментов,
- разложение по ортонормальному базису,
- использование сплайнов.

Идентификация объектов с распределенными параметрами

2. Оптимизация

- **Вариационные методы** дают возможность найти состояние системы и/или зависящие от состояния, времени и координат параметры как экстремумы функционала качества (критерия).
- **Методы теории оптимального управления** используются обычно в задачах оценки состояния.
- **Методы нелинейного программирования** применяются, когда имеются априорные сведения о нелинейности уравнений и/или краевых условий либо о нелинейности зависимости идентифицируемых величин от координат и/или времени.

Идентификация: 90-е +

Идентификация объектов с распределенными параметрами

Спектральная теория для систем с распределенными параметрами
Введено понятие **спектральной характеристики по пространственной переменной**.

Дифференциальное уравнение с частными производными на основании свойств спектральных характеристик может быть представлено бесконечномерной системой обыкновенных дифференциальных уравнений в форме Коши, правая часть которых содержит члены, учитывающие граничные условия и внешние возмущения.

Нечеткие модели – на основе представления СРП в виде многосвязной сосредоточенной системы.

Нейросетевые модели. Применение к СРП обусловлено затруднением применения стандартных методов идентификации вследствие нелинейности моделей, большого объема данных, неточности их измерений, а также высокой вычислительной сложностью классических методов.

Идентификация: 90-е +

Методы идентификации структуры

- выбора операторов или систем уравнений, описывающих процессы в исследуемой системе.

Этапы структурной идентификации:

- Определение формы модели: выбор математического выражения (дифференциальные уравнения, полиномы, логические правила).
- Определение пространства модели: выбор системы координат или степеней свободы.
- Верификация: проверка адекватности выбранной структуры экспериментальным данным.

Оценка размерности объекта в условиях неопределенности

Критерии Акаике: оценка финальной ошибки предсказания; информационный критерий Акаике; байесовский информационный критерий (BIC); критерий Шварца (SC).

Идентификация: 90-е +

Методы идентификации структуры

Аналитические и эвристические подходы

Анализ по экспериментальным данным: выбор структуры на основе формы переходных или импульсных характеристик (например, метод ступенчатого воздействия).

Переборные процедуры: проверка множества гипотез о структуре в заданном классе моделей до достижения требуемой точности.

Математические алгоритмы и оптимизация

Методы иерархического погружения для оценки структурных параметров сложных нелинейных систем.

Генетические алгоритмы (GA). Используются для минимизации целевых функций и поиска оптимальной структуры динамических систем.

Линейная аппроксимация: алгоритмы, основанные на сравнении реального процесса с упрощенными линейными моделями для определения степени нелинейности.

Нейросетевые и гибридные методы: использование глубокого обучения для автоматического выбора типа модели (например, для нечетких или блочно-ориентированных систем).

Bayesian tools: применение байесовских сетей и фильтров Калмана для уточнения структуры в условиях неопределенности.

Л. ЛЬЮНГ

Пленарный доклад на
17 WC IFAC,
Сеул, Южная Корея,
2008

Perspectives on System Identification

Теория статистического обучения

Statistical Learning Theory, SLT

Машинное обучение

Machine Learning

Интеллектуальный анализ данных

Data mining

Mathematical statistics and time series analysis (cf Section 3.2) is in many respects the “mother” field of System Identification, see e.g. Deistler (2002). Here many of the basic results of Section 2 were developed. Statistics is clearly a very broad field, and it is not meaningful to give terse summary of recent trends.

Among developments with relevance to System Identification are for example the *bootstrap*, see e.g. Efron and Tibshirani (1993), and the EM algorithm, (Dempster et al., 1977). Other results of relevance to order selection are new techniques for regularization (variants of (5b)), such as *Lars*, *Lasso*, *NN-garotte*, see e.g. Hastie et al. (2001).

3.2 Econometrics and Time Series Analysis

Econometrics is a science that has grown out of statistics for extracting information from economic data, taking into account both the special features of such data and the a priori information coming from economic theory. Econometrics has a long tradition of giving inspiration to time series and difference equation modeling and its roots coincide with developments in statistics. The work on time series dates back to Jevons (1884), Yule (1927), and Wold (1938). The classic paper Mann and Wald (1943) developed the asymptotic theory for the LS estimator for stochastic linear difference equations (AR systems). The results were extended to simultaneous (multivariate) systems, where LS is not consistent, in Koopmans et al. (1950), where also central identifiability issues were sorted out and Gaussian Maximum Likelihood estimates were proposed and analyzed. Important extensions to the ARMA(X) case have been proposed by Anderson (1971) Hannan (1970) later on. The problem of errors-in-variables modeling (when there are disturbances on both input and output measurements) also has its origins in econometrics, (Frisch, 1934).

More recently, important focus has been on describing volatility clustering, i.e. more careful modeling of conditional variances for modeling and forecasting of risk (GARCH models, (Engle, 1982)), as well as on describing non-stationary behavior of interesting variables in terms of a common stationary linear combination (“cointegration”), (Engle and Granger, 1987), which gives the long run equilibrium relation between these variables. These two subjects were in focus for the Sveriges Riksbanks Prize in Economic Sciences in memory of Alfred Nobel in 2003.

3.3 Statistical Learning Theory

The coining of the term *Statistical learning*, e.g. Vapnik (1998), Hastie et al. (2001), has moved the fields of statistics and *Machine learning* closer together. Much

of the co-operation have been played an essential role, e.g. Bartlett et al. (2006).

3.4 Machine Learning

The term *machine learning* was coined in Artificial Intelligence, see e.g. the classical book Nilsson (1965). The area has housed many approaches, like Kohonen’s self-organizing and self-learning maps, (Kohonen, 1984), to Quinlan’s tree-learning for binary data, (Quinlan, 1986), and the early work on perceptrons, (Rosenblatt, 1962), that later led to neural networks. More recent efforts, include Gaussian Process Regression (kriging), e.g. Rasmussen and Williams (2006), which in turn can be traced back to general nonlinear regression. Overall, the fields on machine learning and statistical learning appear to be converging.

3.5 Manifold Learning

Another “learning topic” is *manifold learning*, which really is the important area of dimension reduction of high-dimensional data to nonlinear manifolds. This is a non-linear counterpart of multivariate data analysis, such as Principal Component Analysis (PCA). Some techniques, like *kernel PCA*, (Schölkopf et al., 1999), are such extensions. Other methods are based on developing proximity matrices, often with nonparametric techniques, such as isomaps and variance unfolding. A special such technique that has been frequently used is LLE (*Local Linear Embedding*), (Roweis and Saul, 2000). It can be described as a way to determine a coordinate system in the manifold that inherits neighborhoods and closeness properties of the original data. Manifold learning has evolved into a community of its own, essentially because of its importance for computer vision and object recognition.

3.6 Statistical Process Control and Chemometrics

The term *chemometrics* is primarily used in process industry and stands for statistical methods for extracting information from data sets that often consist of many measured variables. The techniques are various forms of Multivariate data analysis, such as PCA, but in Chemometrics the use of Partial Least Squares (PLS), (Wold et al., 1984), has been a predominant way of projecting data onto linear subspaces. For a recent survey, see MacGregor (2003). The PLS methods are conceptually related to *subspace methods* in System Identification. The term (*Multivariate*) *Statistical Process Control* refers to identifying important indicators for the process and keeping track of their changes.

3.7 Data Mining

Data Mining or Knowledge Discovery has become a buzzword for sorting through large databases and finding relevant information. Data mining has been applied to a

Тенденции

Л. Льюнг

Изменит ли машинное обучение парадигму идентификации?

The video player displays a presentation slide with the title "Will Machine Learning Change the Paradigm of System Identification?" and a list of bullet points. The slide also features a logo for "САНКТ-ПЕТЕРБУРГСКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ ИМЕНИ ДМИТРИЯ АНДРЕЕВИЧА МЕДВЕДЕВА". On the right side of the video player, a man in a suit and glasses is standing and speaking. The video player interface includes a progress bar at 1:13 / 25:18, and standard video control icons like play, pause, and volume.

Will Machine Learning Change the Paradigm of System Identification?

- The paradigm of System Identification
- A function learning approach to estimating impulse response functions
- Using System Identification thinking in more thoughtful way

к 70-летию Хейкки Койво 24.1.2014
Университет Аалто, Отаниеми,
Эспоо, Финляндия.

Master classes in China, Sep 2018: Data
Science: From System Identification to
(Deep) Learning and Big Data.

Идентификация систем. Тенденции и тренды

Конгресс IFAC, Берлин 2020:

Пленарное заседание Learning and Control

Reflections on the Learning-to-Control Renaissance (Benjamin Recht)

Дискуссия: "Control and learning – is there really a divide?"

Пленарное заседание

Reinforcement Learning for Process Control and Beyond

Reinforcement Learning for Process Control and Beyond (Jay H. Lee)

Дискуссия: "Industrial Potential of Reinforcement Learning"

Data driven modeling – построение моделей на основе обработки и анализа больших данных в реальном времени.

Идентификация - построение математической модели объекта/системы посредством анализа данных функционирования (реального либо экспериментального).

Особенности

В основе современных методов **Data driven modeling** лежат **машинное обучение (Machine Learning)** и **нейронные сети**.

Методы машинного обучения

— это алгоритмы (обучение с учителем, без учителя, с подкреплением), которые извлекают закономерности из данных для классификации, прогнозирования и принятия решений.

Основные типы машинного обучения:

Обучение с учителем (Supervised Learning): Модель обучается на размеченных данных (вход + правильный ответ). Используется для классификации и регрессии.

Обучение без учителя (Unsupervised Learning): Модель ищет скрытые закономерности в неразмеченных данных. Применяется для кластеризации и снижения размерности.

Обучение с подкреплением (Reinforcement Learning): Модель взаимодействует со средой и получает «вознаграждение» за правильные действия.

Глубокое обучение (Deep Learning): Подмножество методов, использующее многослойные нейронные сети для анализа сложных данных (изображения, звук).

Методы машинного обучения

— это алгоритмы (обучение с учителем, без учителя, с подкреплением), которые извлекают закономерности из данных для классификации, прогнозирования и принятия решений.

Алгоритмы:

Линейная регрессия: прогнозирование значений коэффициентов.

Логистическая регрессия: бинарная классификация.

Решающие деревья (Decision Trees): иерархическая структура вопросов и ответов.

Случайный лес (Random Forest): ансамбль из множества решающих деревьев.

Градиентный бустинг (Gradient Boosting): последовательное построение моделей для исправления ошибок предыдущих.

k-ближайших соседей (KNN): классификация по принципу большинства среди соседей.

Метод опорных векторов (SVM): поиск оптимальной границы между классами.

Нейронные сети.



Идентификация сегодня

□ Методы на основе мягких вычислений.

М.В. (Л. Заде, 1994) - неточные, приближённые методы решения задач, не дающие решение за полиномиальное время.

Нечёткие модели, генетические алгоритмы, эволюционное («роевое») моделирование.

Вероятностные рассуждения (Probabilistic Reasoning) - для оценки неопределенности и принятия решений в условиях риска (например, байесовские сети)

□ Reinforcement learning – обучение с подкреплением

□ Методы идентификации на основе нейронных сетей

□ Методы на основе регуляризации

□ Методы, основанные на теории статистического обучения (Statistical Learning Theory, SLT), обучение по прецедентам.

□ Алгоритмы, использующие индуктивные знания

□ Situational Awareness – моделирование ситуаций

– учет при построении моделей информации о состоянии внешней среды



Идентификация сегодня

□ Алгоритмы обучения с подкреплением для решения задач прогнозирования и управления

- система обучается, получая награды/наказания за свои действия,
Цель — выработать оптимальную стратегию (политику), которая приведет к максимальной сумме наград.

Методы, основанные на семплинге (Монте-Карло, метод временных различий, Q-learning, SARSA, Expected SARSA) - позволяют решать задачи прогнозирования и управления **без полной математической модели среды**, используя накапливаемый опыт взаимодействия.



Идентификация сегодня

- Алгоритмы обучения с подкреплением для решения задач прогнозирования и управления

Обучение с подкреплением на основе модели (**Model-Based reinforcement learning**) - подход в машинном обучении, при котором система обучает модель среды, чтобы предсказывать её будущие состояния и размер награды.

В отличие от безмодельного обучения (**Model-Free RL**), когда система учится «методом проб и ошибок» непосредственно в реальности, MBRL- алгоритм строит имитацию взаимодействия системы со средой.

Алгоритмы

Dyna-Q: один из классических алгоритмов, сочетающий прямое обучение и планирование по модели.

World Models: система учится полностью внутри компактного представления среды (VAE + RNN).

PETS / PlaNet / Dreamer: управление роботами и решения сложных визуальных задач.



Идентификация сегодня

- Идентификация систем с помощью нейронных сетей (НС) – процесс создания математических **моделей динамических объектов** путем **обучения нейросетевых структур на данных типа «вход-выход»**.

Идентификация сегодня

□ Алгоритмы идентификации, основанные на нейронных сетях

Используются для идентификации:

- **Рекуррентные нейронные сети (RNN):** эффективны для моделирования динамики систем с учетом предыдущих состояний.
- **Сверточные нейронные сети (CNN).** Применяются для идентификации объектов в видеопотоках и обработки пространственных данных.
- **Физико-информированные нейронные сети (PINN).** Подход, использующий известные физические законы совместно с анализом данных (например, уравнения в частных производных), что повышает точность при недостаточном объеме данных.
- **Нейро-нечеткие модели (Neuro-fuzzy).** Комбинируют НС с интерпретируемостью нечеткой логики, часто используются для нелинейных объектов.

Идентификация сегодня

□ Алгоритмы идентификации, основанные на нейронных сетях

Особенности моделирования для разных случаев

Черный ящик (Black-box). Идентификация системы исключительно по данным без априорных знаний о её внутренней структуре.

Известны входные и выходные данные, но внутренние **процессы преобразования информации остаются скрытыми или слишком сложными для семантической интерпретации.**

Глубокие нейросети (DNN) содержат миллионы параметров (весов), что делает невозможным отслеживание логики конкретного решения.

Нелинейность модели: множество слоев и функций активации создают сложные математические зависимости.

Идентификация сегодня

□ Алгоритмы идентификации, основанные на нейронных сетях

Особенности моделирования для разных случаев

Черный ящик (Black-box). Идентификация системы исключительно по данным без априорных знаний о её внутренней структуре.

Серый ящик (Gray-box). Использование частичных знаний о физике процесса для структурирования нейросетевой модели.

Оператор Купмана (Koopman operator). Апроксимация нелинейной динамики линейными операторами в высокоразмерном пространстве признаков с помощью НС.

Вариационные автокодировщики (VAE). Применяются для построения стохастических моделей, обеспечивая не только точечные оценки, но и **распределение вероятностей состояний** системы.

Идентификация сегодня

□ Алгоритмы идентификации, основанные на нейронных сетях

Обучение и настройка

Обратное распространение ошибки (Backpropagation): Стандартный алгоритм минимизации функции потерь для настройки параметров модели.

Градиентный спуск. Базовый метод оптимизации и его модификации, такие как стохастический (SGD).

Алгоритм Левенберга — Марквардта (LMA) — построение моделей с использованием **нелинейного метода наименьших квадратов**. Объединяет два других метода оптимизации: метод градиентного спуска и метод Гаусса — Ньютона.

Нейронная сеть с нелинейной авторегрессионной экзогенностью (**NARX** - Nonlinear AutoRegressive with eXogenous inputs) — это тип рекуррентной нейронной сети, предназначенный для моделирования и прогнозирования **нелинейных временных рядов**.

Идентификация сегодня

Обратное распространение ошибки (Backpropagation):

Модель рассматривается как «черный ящик» с настраиваемыми весами. Цель — минимизировать разницу между реальным выходом системы y и предсказанием модели \hat{y} .

Алгоритм идентификации

1. **Прямой проход:** На вход модели подаются те же сигналы управления $u(t)$, что и на реальный объект. Модель вычисляет прогноз $\hat{y}(t)$.
2. **Вычисление функции потерь:** Определяется ошибка

$$e = y - \hat{y}$$

Обычно используется среднеквадратичная ошибка:

$$E = \frac{1}{2} (y - \hat{y})^2$$

3. **Обратный проход:** Вычисляются градиенты ошибки по всем весам модели, используя правило дифференцирования сложной функции (chain rule).
4. **Обновление параметров:** Веса корректируются в сторону, противоположную градиенту:

$$w_{new} = w_{old} - \eta \frac{\partial E}{\partial w},$$

где η — скорость обучения.

Идентификация сегодня

Обратное распространение ошибки. Проблемы применения

- **Локальные минимумы:** алгоритм может «застрять» в точке, где значение ошибки ниже, чем в окрестностях, но выше, чем в глобальном минимуме.
- **Переобучение:** модель хорошо работает на обучающей выборке, но может плохо работать на новых данных.
- **Затухание градиентов:** при идентификации длительных процессов градиент может «исчезать», что делает обучение невозможным без использования специальных архитектур (например, LSTM).
- **Седловые точки:** градиент равен нулю, но по одним осям это минимум, а по другим — максимум. В глубоком обучении они встречаются чаще, чем локальные минимумы, и замедляют обучение.
- **Плато:** области с очень малым градиентом, где процесс минимизации практически останавливается.
- **Взрывные градиенты:** препятствуют корректному обновлению весов на глубоких слоях.



Идентификация сегодня

Обратное распространение ошибки.

Решение проблем

- **Методы оптимизации:** Использование **алгоритмов с адаптивным шагом обучения и моментом** (Momentum, RMSprop, Adam, Lion), которые помогают «проскаакивать» мелкие локальные минимумы и преодолевать седловые точки.
- **Инициализация весов:** Методы Xavier позволяют стартовать из более удачных точек ландшафта.
- **Функции активации:** ReLU и её вариации (Leaky ReLU, ELU) помогают бороться с затуханием градиентов на плато.
- **Нормализация:** (Batch Normalization, Layer Normalization) сглаживает ландшафт функции потерь, делая его менее «изрезанным».
- **Сложные стратегии:** Обучение с **уменьшением шага** (Learning Rate Decay) или **циклическим форматом обучения** (Cyclic LR).



Идентификация сегодня

Обратное распространение ошибки (Backpropagation):

Идентификация динамических систем

Модификация стандартного backpropagation -

Backpropagation Through Time (BPTT): для рекуррентных сетей, чтобы учесть память системы.

Развертывание во времени (Unrolling): Для вычисления градиентов NN «развертывается» в глубокую полносвязную сеть, **каждый слой формализует конкретный шаг во времени** ($t, t+1, \dots$) Количество слоев равно длине входной последовательности.

Разделение весов (Weight Sharing): В отличие от обычных сетей, на каждом временном шаге используются одни и те же матрицы весов. При обновлении весов градиенты, вычисленные для каждого шага, суммируются.



Идентификация сегодня

Обратное распространение ошибки (Backpropagation):

Идентификация динамических систем

Backpropagation Through Time (BPTT): для рекуррентных сетей, чтобы учесть память системы.

- **Накопление ошибки:** Ошибка вычисляется на каждом шаге (или только в конце), и градиент «перемещается» от текущего момента времени назад к самому началу последовательности.

Проблемы алгоритма:

- **Затухающие градиенты (Vanishing Gradients):** При очень длинных последовательностях произведение производных в цепочке может стать близким к нулю. Сеть «забывает» информацию из начала последовательности и перестает обучаться на ранних этапах.

- **Взрывные градиенты (Exploding Gradients):** Градиенты могут расти экспоненциально, что приводит к резким скачкам весов и дестабилизации обучения (решается с помощью *Gradient Clipping*).

- **Вычислительная сложность:** BPTT требует больших затрат памяти и времени, так как нужно хранить все промежуточные состояния для каждого шага последовательности.

Оптимизация (Truncated BPTT):

Для работы с длинными данными часто используют **Truncated BPTT** (усеченный BPTT). В этом случае **обратный проход ограничивается фиксированным количеством шагов** (например, назад только на 10–20 шагов), что экономит ресурсы и помогает⁶⁷ избежать сильного затухания градиентов.

Идентификация сегодня

□ Методы на основе регуляризации

в задачах идентификации (моделирования) помогают **решать некорректно поставленные или плохо обусловленные задачи**, добавляя штрафные члены к функции потерь для предотвращения **переобучения и стабилизации решений**

Использование **статистической теории обучения для описания моделей, которые строятся на принципах теории регуляризации Тихонова**.
Модель минимизирует функцию вида:

$$L_{reg}(w) = L(w) + \lambda \cdot R(w)$$

- $L(w)$ – стандартная ошибка (насколько плохо модель предсказывает данные);
- $R(w)$ – регуляризатор (штраф за величину весов w)

Основные свойства

Предотвращение переобучения: модель не просто запоминает тренировочные данные, а выявляет общие закономерности, пригодные для новых данных.

Идентификация сегодня

□ Методы на основе регуляризации

- **L1-регуляризация (Lasso):** штрафует сумму абсолютных значений весовых коэффициентов, что может приводить к обнулению некоторых коэффициентов и отбору признаков, полезных для идентификации.
- **L2-регуляризация (Ridge):** штрафует сумму квадратов весовых коэффициентов, уменьшая их величины и делая модель менее чувствительной к шуму, снижая сложность модели.
- **Динамическая регуляризация:** параметр регуляризации изменяется от итерации к итерации, адаптируясь к ошибке и позволяя устойчиво идентифицировать негладкие возмущения в сложных системах.
- **Комбинированная регуляризация (Elastic Net):** объединяет L1 и L2 регуляризацию, сочетая отбор признаков и снижение влияния весов.

Известно **более 2000 методов регуляризации** для разных моделей и алгоритмов идентификации

Идентификация сегодня

□ Методы идентификации на основе регуляризации

Сети регуляризации - (Regularization Networks) — обучение нейронных сетей и других моделей как **задача минимизации функционала, состоящего из ошибки на данных и штрафа за сложность.**

Типичные методы в таких сетях:

L2-регуляризация (Ridge): штрафует квадрат весов, предотвращая их чрезмерный рост и делая модель более устойчивой.

L1-регуляризация (Lasso): штрафует абсолютное значение весов, что может занулять некоторые из них, создавая разреженные (sparse) модели.

Dropout (Дропаут). Метод для нейронных сетей, когда во время обучения случайно «выключаются» нейроны, чтобы избежать их сложной коадаптации.

Early Stopping: остановка обучения, когда ошибка на проверочных данных начинает расти, несмотря на снижение ошибки на тренировочных

Идентификация сегодня

□ Структурная идентификация на основе регуляризации

Структура модели В классическом подходе к решению задачи параметрической настройки сложность (порядок) модели **необходимо выбирать, как правило, из конечного семейства альтернатив.**

В подходах, основанных на регуляризации, **структура модели контролируется путем настройки параметров регуляризации**, что делает выбор модели более надежным.

Идентификация сегодня

□ Методы идентификации на основе ядра

Ядерные методы (kernel methods) в идентификации систем и машинном обучении позволяют решать **нелинейные задачи**, используя алгоритмы для линейного анализа.

Основная идея

Вместо выявления нелинейной зависимости в исходном пространстве признаков, **данные отображаются в пространство более высокой размерности («спрямляющее пространство»)**, где зависимость становится линейной.

Ядерный переход (Kernel Trick): — это метод, позволяющий алгоритмам оперировать в высокоразмерных пространствах признаков без явного вычисления координат объектов в этих пространствах.

Позволяет **вычислять скалярное произведение объектов в высоко-размерном пространстве напрямую через функцию ядра $K(x, x')$** , не выполняя само преобразование признаков в явном виде, что экономит вычислительные ресурсы.

Идентификация сегодня

□ Методы на основе ядра

Ядерные методы (kernel methods) в идентификации систем и машинном обучении позволяют решать нелинейные задачи, используя алгоритмы для линейного анализа.

Собственно ядром является любая симметричная, положительно полуопределенная матрица \mathbf{K} , которая составлена из скалярных произведений пар векторов \mathbf{x}_i и \mathbf{x}_j :

$K(\mathbf{x}_i, \mathbf{x}_j) = \langle \phi(\mathbf{x}_i), \phi(\mathbf{x}_j) \rangle$ характеризующих меру их близости. Здесь ϕ - произвольная преобразующая функция, формирующая ядро. В качестве таких функций чаще всего используют следующие:

- линейное ядро: $K(\mathbf{x}_i, \mathbf{x}_j) = \mathbf{x}_i^T \mathbf{x}_j$, что соответствует классификатору на опорных векторах в исходном пространстве (см. рис. 6.3);
- полиномиальное ядро со степенью p : $K(\mathbf{x}_i, \mathbf{x}_j) = (1 + \mathbf{x}_i^T \mathbf{x}_j)^p$;
- гауссово ядро с радиальной базовой функцией (RBF): $K(\mathbf{x}_i, \mathbf{x}_j) = \exp(\gamma ||\mathbf{x}_i - \mathbf{x}_j||^2)$;
- сигмоидное ядро: $K(\mathbf{x}_i, \mathbf{x}_j) = \tanh(\gamma \mathbf{x}_i^T \mathbf{x}_j + \beta_0)$.

Каждое ядро характеризуется параметрами (p, γ, β_0 и т.д.), которые подлежат оптимизации.

Идентификация сегодня

□ Ядерные методы (kernel methods) в идентификации систем

Применение в идентификации

Идентификация нелинейных систем (Nonlinear AutoRegressive network with eXogenous inputs - NARX) - построение моделей авторегрессии с внешними входами, где структура системы заранее неизвестна.

Методы

Ядерный метод опорных векторов (Support Vector Regression, SVR) — алгоритм машинного обучения, используемый для построения регрессионных моделей нелинейных систем. Является модификацией классического метода опорных векторов (SVM), предназначенного для классификации.

Ядерный метод главных компонент (Kernel PCA) — это расширение классического метода главных компонент (PCA). Позволяет выделять нелинейные главные компоненты для снижения размерности данных в сложных многомерных системах. .

Регуляризация. Ядра используются для задания априорных знаний о гладкости и структуре идентифицируемой системы.



Идентификация сегодня

□ Методы на основе ядра

Ядерные методы (kernel methods) в идентификации систем

Преимущества

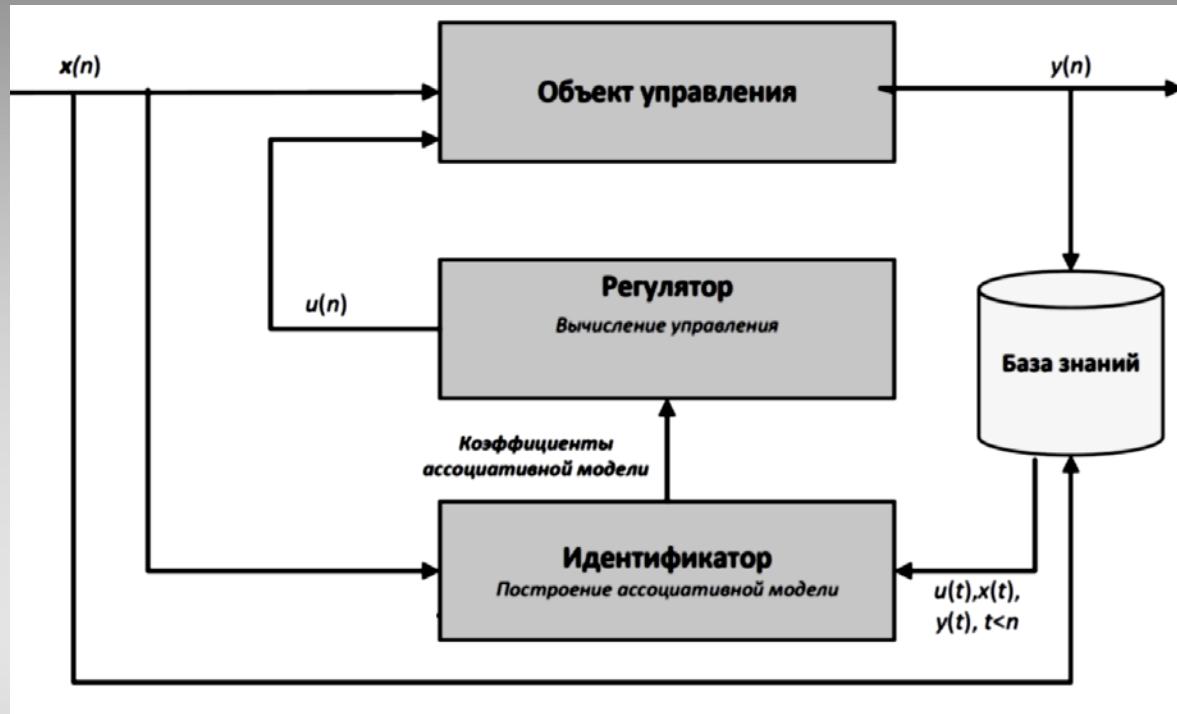
- Эффективная работа с нелинейностями без необходимости точного моделирования физики процесса.
- Выпуклая оптимизация (отсутствие локальных минимумов в отличие от нейросетей).
- Хорошая обобщающая способность при малых выборках.

Осип Мандельштам:

*«И я выхожу из пространства
В запущенный сад величин
И мнимое рву постоянство
И самосознанье причин.»*

Идентификация сегодня

Методы идентификации на основе ассоциативного поиска



Алгоритмы АП, используют
индуктивные знания
– закономерности, извлекаемые из всей совокупности данных об объекте и его функционировании на основе их анализа

*Associative Search Models in Industrial systems / N. Bachtadze,
V. Lototsky, E. Maximov, B. Pavlov // IFAC International Conference on
Intelligent Manufacturing Systems (IMS'07) — Alicante, Spain, 2007. — Vol. 1.
— P. 120—126.*

Идентификация сегодня

Методы ассоциативного поиска

1. Методы, в отличие от традиционных, не проводят адаптивную настройку модели, а осуществляют **в каждый момент времени формирование новой цифровой модели** - «обучение по принципу «точно в срок» (*Just-in-time learning (JITL)*)».

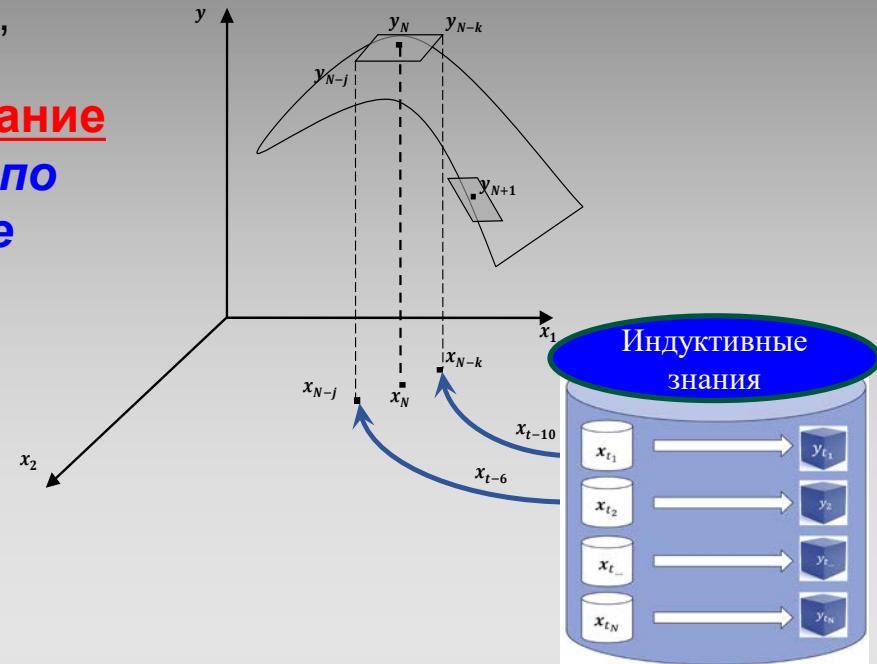
2. Генерируются **линейные** цифровые модели, которые используют **индуктивные знания** о динамике исследуемых процессов и реализуют схему решения задачи на основе **прецедентов (case-based reasoning, CBR)**

Кластеризация
данных

Из кластера производится отбор пар значений $x_{N-j,s}$ и y_{N-i} :

$$d(\overline{x_N}, \overline{x_{N-j}}) \leq D_N,$$

и соответствующих выходов

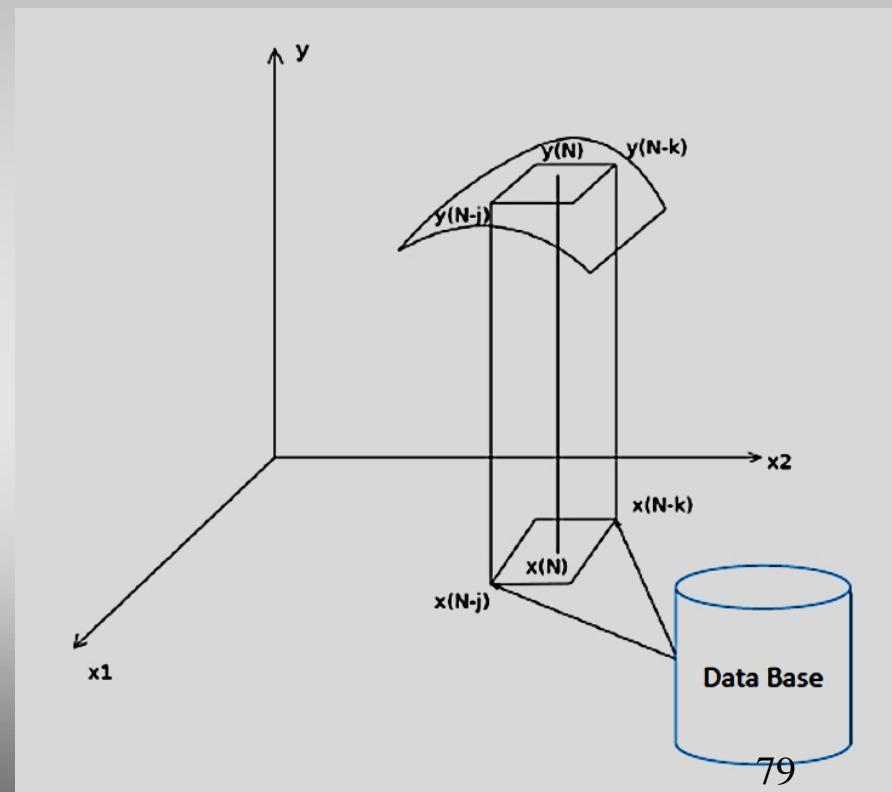


В соответствии с МНК находятся коэффициенты линейной модели

Идентификация сегодня

Методы идентификации на основе ассоциативного поиска

- Процесс извлечения индуктивных знаний сводится к восстановлению (ассоциативному поиску) знания по его фрагменту
- Знание интерпретируется как ассоциативная связь между образами.
- В качестве **образа** используются «наборы признаков», т.е. компонент векторов входов – входных переменных.





Методы идентификации на основе ассоциативного поиска: приложения

- Идентификация технологических процессов непрерывных и полу-непрерывных промышленных производств (в частности, химических и нефтепереработки).
- Программно-алгоритмические комплексы автоматизации управления технологическими процессами химических производств и нефтепереработки.
- Системы управления качеством производства минеральных удобрений.
- Динамическая оценка и прогнозирование в реальном времени состояния энергосистемы (загрузки критических сечений сети и уровней напряжения, качественных характеристик режима и надежности его состояния).
- Методы автоматической дистанционной диагностики готовности к общему первичному регулированию частоты (ОПРЧ) генерирующего оборудования электростанций в ходе реальной эксплуатации.
- Методы управления режимами систем электроснабжения в общей системе иерархического координированного адаптивного управления режимами ЕЭС.
- Прогнозирования характерных технологических ситуаций (включая нештатные) доменного процесса на основе анализа видеопотока данных с видеокамер на формах доменной печи в режиме реального времени.

Моделирование и прогноз в режиме реального функционирования:

- состояния комплекса ресурсов базового ЦУП РОСКОСМОС
- состояния ресурсов промышленного предприятия
- динамики спроса в маркетинге
- динамики фондового рынка на основе интеллектуальных алгоритмов для процессов трейдинга
- состояния комплекса ресурсов базового ЦУП РОСКОСМОС
- состояния ресурсов промышленного предприятия
- спроса в маркетинге
- динамики фондового рынка на основе интеллектуальных алгоритмов для процессов трейдинга
- Методы идентификации в производственной и транспортной логистике: методы прогнозирования объема автоперевозок и показателей, характеризующих эффективность расписания на основе исследования динамики перевозочных процессов
- ...



Примеры. Прогноз выкипания 10% керосиновой фракции для установки ЭЛОУ-АВТ-6

- Комплекс первичной переработки нефти мощностью 6 млн тонн в год объединяющий **процессы электрообессоливания (ЭЛОУ)**, атмосферной (АТ) и вакуумной (ВТ) перегонки.

Нефть очищается от солей/воды и разделяется на фракции: бензин, керосин, дизельное топливо, вакуумные газойли и гудрон.

$$T(t) = \sum_{i=1}^4 b_i F_i(t-1) + b_5 F_5(t-3) + b_6 F_6(t-5) + \sum_{i=7}^{12} b_i F_i(t-7),$$

где $T(t)$ – прогноз значения температуры выкипания 10% фракции «150-250°C»; F_1 – текущее значение расхода нефти после Н1 (3 поток); F_2 – текущее значение расхода фр.62-105°C с установки; F_3 – текущее значение расхода фр.290-350 С с установки; F_4 – текущее значение расхода сырой нефти перед обессоливанием на установку;

F_5 – значение расхода циркулирующей флегмы от Н-11/1,2, Т-20 в П-2/2 (1 поток) в момент времени $t - 3$;

$F_6(t - 5)$ – значение расхода фр.150-250°C С цех 2 в момент времени $t - 5$;

$F_7(t - 7)$ – значение расхода фр.НК85°C с установки в момент времени $t - 7$; $F_8(t - 7)$ – значение расхода воздуха горения П1-1 в момент времени $t - 7$;

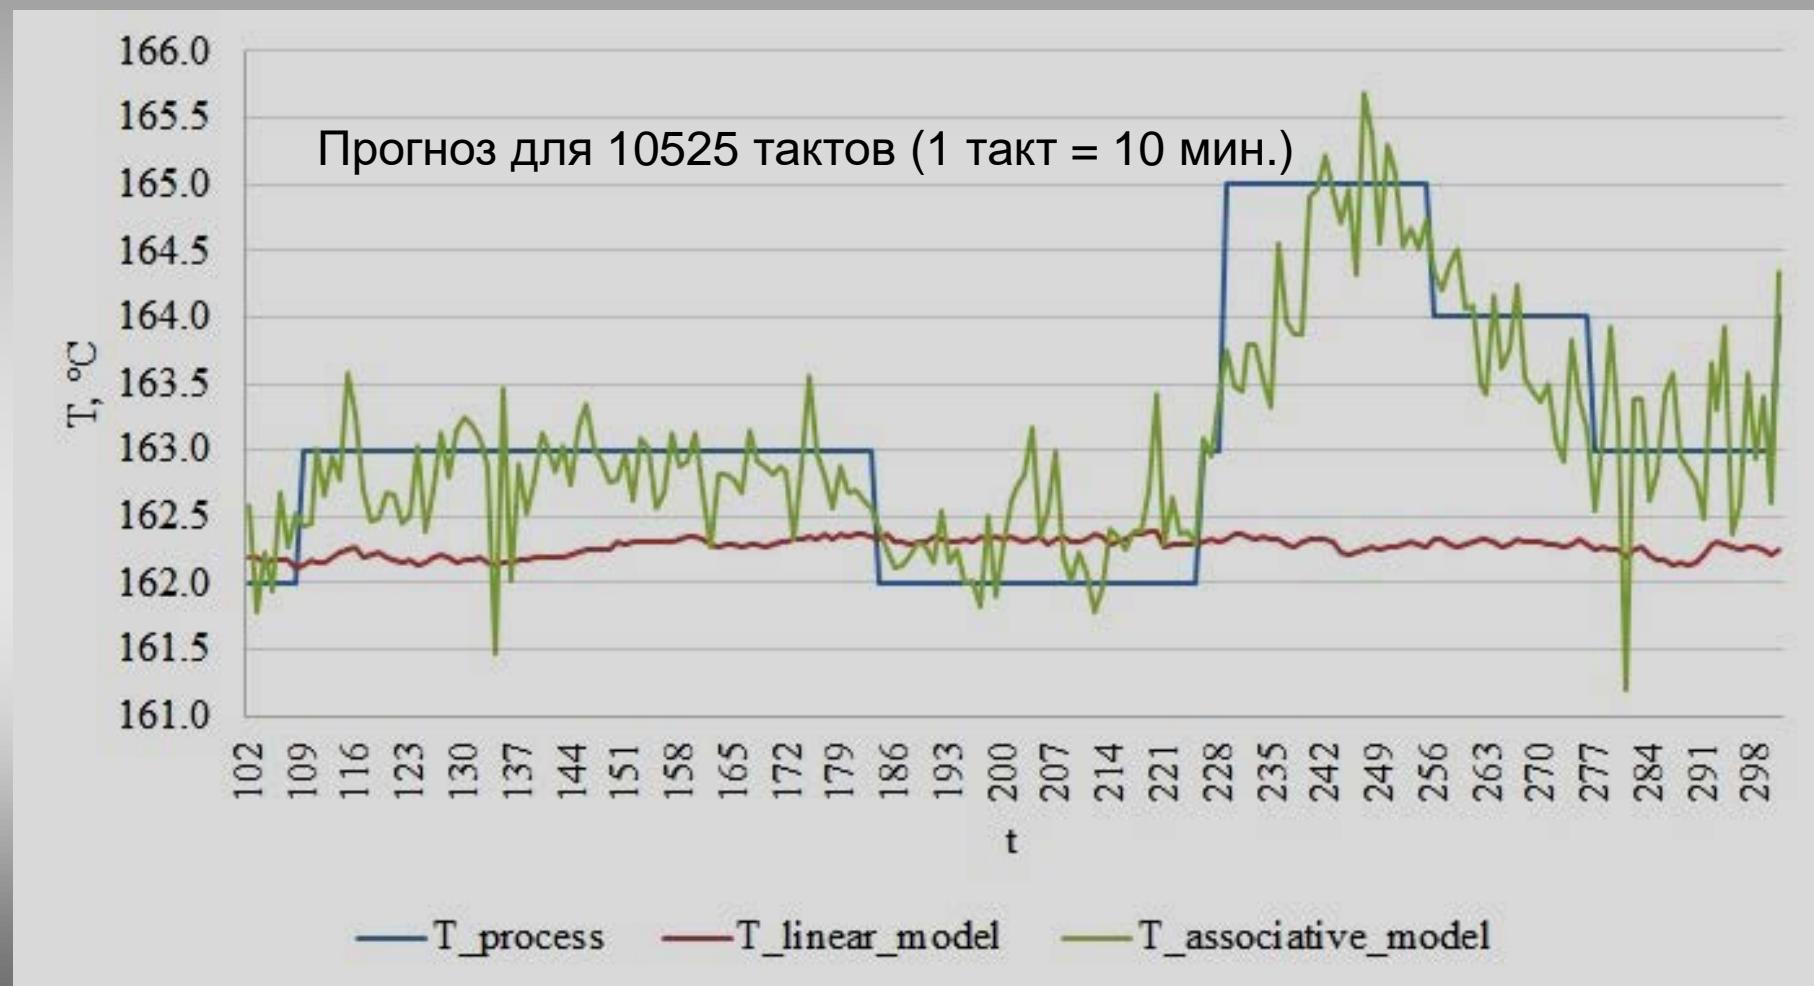
$F_9(t - 7)$ – значение расхода воздуха горения П1-1 в момент времени $t - 7$; $F_{10}(t - 7)$ – значение расхода раствора щелочи 2-ого хода после ЭДГ в момент времени $t - 7$; $F_{11}(t - 7)$ – значение расхода циркулирующей

флегмы от Н-11/1,2, Т-20 в П-2/2 (3 поток) в момент времени $t - 7$;

$F_{12}(t - 7)$ – значение расхода воды в Э-1/1 в момент времени $t - 7$; b_1, \dots, b_{12} – коэффициенты модели.

Прогноз температуры выкипания 10% керосиновой фракции для установки ЭЛОУ-АВТ-6

Данные лабораторного анализа температуры выкипания 10% фракции «150-250°C» ($T_{process}$) по времени t , прогноз температуры выкипания 10% фракции «150-250°C» на основе линейной модели (T_{linear_model}) и ассоциативной модели ($T_{associative_model}$)



Трейдинг. Прогноз цены акций компании

Профиль компании: WY / Weyerhaeuser Company -интегрированный лесопромышленный холдинг. Рыночная капитализация 159 млрд.дол.

Пусть выбрана модель, имеющая следующую структуру:

$$S_N = \sum_{j=0}^2 a^j S_{p-i_0+j} + \sum_{i=0}^2 b^i M_{N-l_1-i} + \sum_{i=0}^2 c^i SP_{N-l_2-i} + \sum_{i=0}^2 d^i EURUSD_{N-l_3-i}$$

где:

$a = (a^0, a^1, a^2)$, $b = (b^0, b^1, b^2)$, $c = (c^0, c^1, c^2)$, $d = (d^0, d^1, d^2)$ - параметры, подлежащие определению;

p, i_0, l_1, l_2, l_3 - индексы в обозначениях п.2.4;

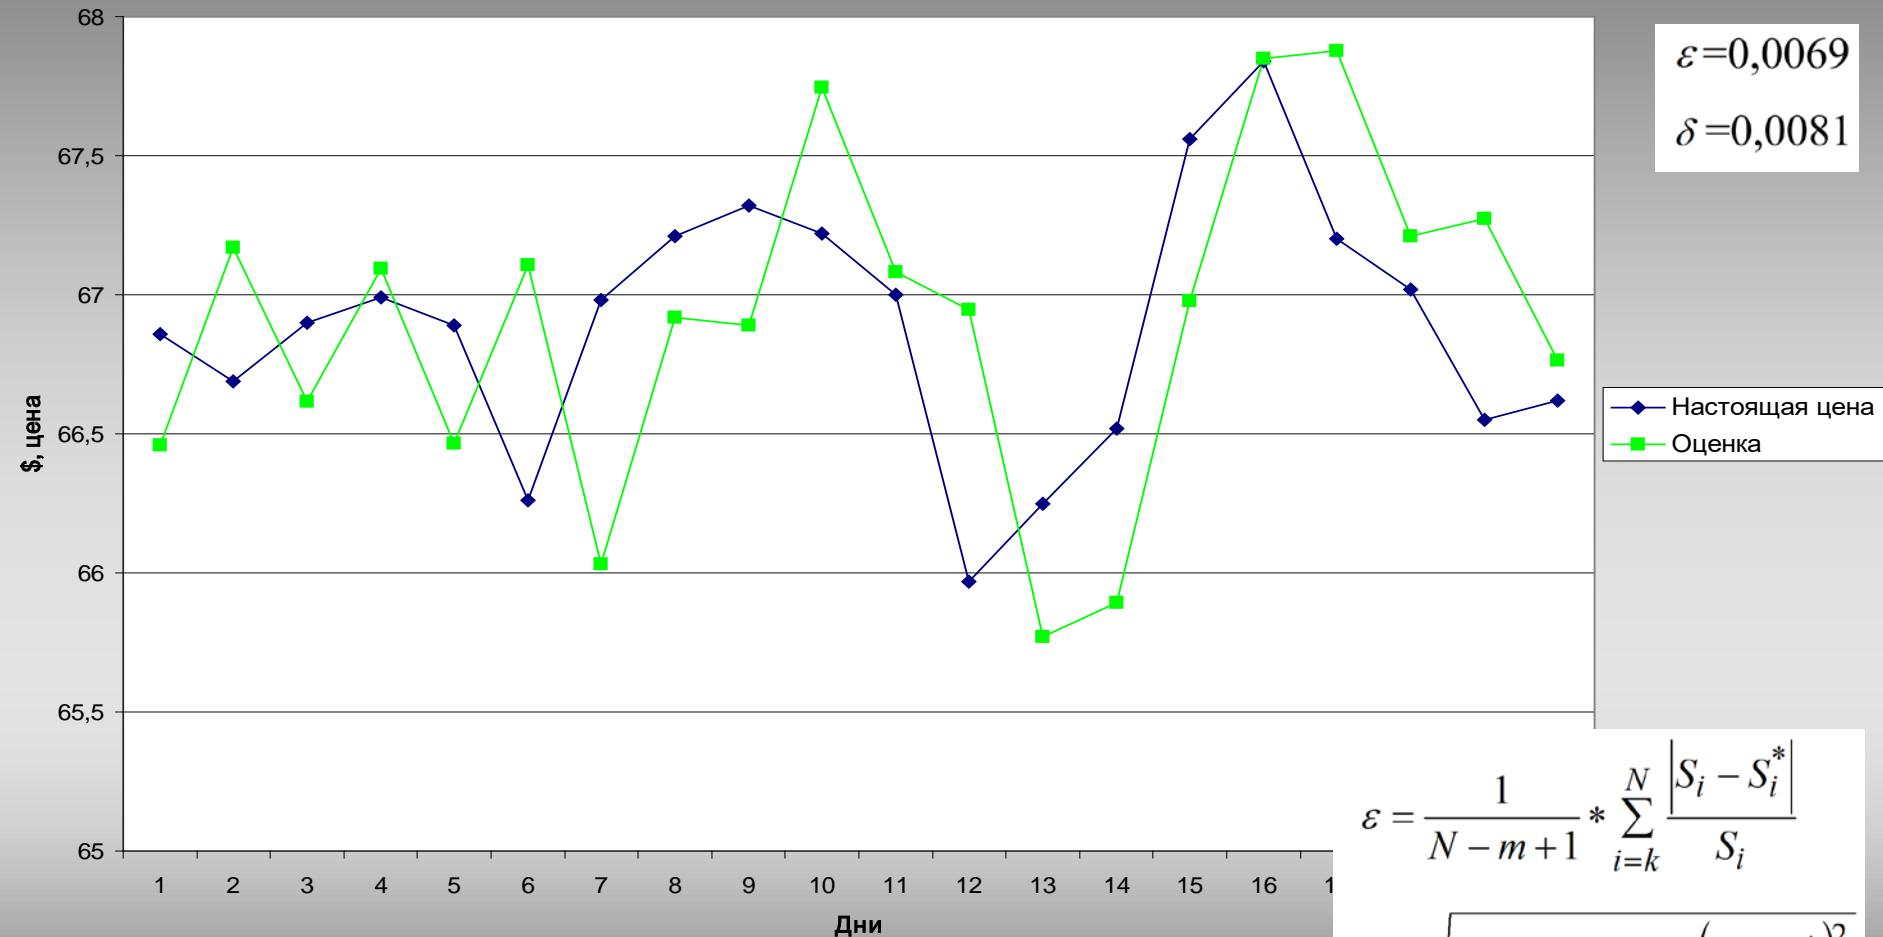
S_N - цена акции в момент времени N;

SP_N - значение индекса S&P500 в момент времени N;

M_N - цена на акцию компании из одинаковой отрасли с S_N .

Трейдинг. Прогноз цены акций компании

Профиль компании: WY / Weyerhaeuser Company - интегрированный лесопромышленный холдинг. Рыночная капитализация 159 млрд. долл. США.



$$\varepsilon = \frac{1}{N-m+1} * \sum_{i=k}^N \frac{|S_i - S_i^*|}{S_i}$$

$$\delta = \sqrt{\frac{1}{N-m+1} * \sum_{i=k}^N \frac{(S_i - S_i^*)^2}{S_i^2}}$$

Моделирование динамики выбросов CO и NOx для газовых турбин

- Энергетика - для выработки электроэнергии.
- Нефтегазовая отрасль - для привода мощных компрессорных установок.
- Авиация - как основа реактивных двигателей.
- Ракетостроение - для питания турбонасосов.
- Промышленность - для обеспечения механической энергии.
- Коммунальное хозяйство - в системах когенерации.
- Морской транспорт - как силовые установки.



Моделирование динамики выбросов CO и NOx для газовых турбин

Эксплуатация газовых турбин связана с выбросами вредных веществ - оксидов азота (**NOx**) и угарного газа (**CO**).

Большее значение приобретает разработка систем экологического прогноза и мониторинга. Одним из эффективных подходов является представление использования **виртуальных анализаторов – цифровых моделей, устанавливающих зависимость между параметрами технологического процесса и контролируемыми показателями.**





Моделирование динамики выбросов CO и NOx для газовых турбин

Данные технологического процесса:

Входные переменные:

- Окружающая среда: температура, влажность и давление.
- Параметры технологического процесса: включая выход энергии турбины и давление перепада в воздушном фильтре.

Данные были собраны в рабочем диапазоне между частичной (75%) и полной (100%) нагрузкой.

Выходные данные

- Выбросыmonoоксида углерода (CO)
- Выбросы оксида азота (NOx).

ТАБЛИЦА 1. Набор переменных для построения моделей

Переменная	Аббревиатура	Единицы измерений
Температура внешней среды	AT	°C
Давление внешней среды	AP	бар
Влажность внешней среды	AH	(%)
Перепад давления в воздушном фильтре	AFDP	бар
Давление выхлопа газовой турбины	GTEP	бар
Температура на входе в турбину	TIT	°C
Температура на выходе из турбины	TAT	°C
Выработка энергии турбиной	TEY	МВт
Давление на выходе из компрессора	CDP	бар
Оксис углерода	CO	мг/м³
Оксид азота	NOx	мг/м³

Моделирование динамики выбросов CO и NO_x для газовых турбин

Использовался **открытый набор данных** из репозитория Калифорнийского университета. Данные охватывают 5 лет мониторинга газотурбинной установки (с 2011 по 2015 гг.) и включают в себя 36 733 набора переменных.

Всего в анализе для построения моделей использовалось 9 входов и 2 выхода (представлены в таблице).

На их основе были разработаны **виртуальные анализаторы для прогноза выбросов оксидов азота и угарного газа.**

Переменная	Аббревиатура	Единицы измерений
Температура внешней среды	AT	°C
Давление внешней среды	AP	бар
Влажность внешней среды	AH	%
Перепад давление в воздушном фильтре	AFDP	бар
Давление выхлопа газовой турбины	GTEP	бар
Температура на входе в турбину	TIT	°C
Температура на выходе из турбины	TAT	°C
Выработка энергии турбиной	TEY	МВт
Давление на выходе из компрессора	CDP	бар
Окись углерода	CO	мг/м ³
Окись азота	NO _x	мг/м ³

Моделирование динамики выбросов CO и NOx для газовых турбин

Сравнительный анализ моделей для прогноза CO

Модель	MAE	MSE	MLSE	R ²
Линейная регрессия	0.860	2.230	0.383	0.559
Линейная регрессия (Lasso)	0.852	2.251	0.377	0.555
Линейная регрессия (Ridge)	0.860	2.230	0.383	0.559
Линейная регрессия (Elastic Net)	0.857	2.353	0.384	0.535
Логарифмическая регрессия	0.763	2.185	0.312	0.568
Метод K ближайших соседей	0.513	1.353	0.247	0.733
Дерево решений	0.658	1.878	0.304	0.628
Случайный лес	0.484	1.217	0.236	0.759
Градиентный бустинг	0.494	1.314	0.240	0.740
Многослойный персепtron	0.603	1.405	0.278	0.729
Ассоциативная регрессия	0.535	1.240	0.246	0.754
Ассоциативная регрессия с регуляризацией	0.532	1.358	0.251	0.731
Кластерная ассоциативная регрессия	0.678	1.687	0.305	0.666
Мультимодальная ассоциативная регрессия	0.571	1.605	0.264	0.681



Моделирование динамики выбросов CO и NOx для газовых турбин

Сравнительный анализ моделей для прогноза NOx

Модель	MAE	MSE	MLSE	R ²
Линейная регрессия	5.773	65.53	0.014	0.523
Линейная регрессия (Lasso)	7.132	86.13	0.019	0.373
Линейная регрессия (Ridge)	5.804	65.70	0.014	0.521
Линейная регрессия (Elastic Net)	7.692	100.3	0.022	0.270
Логарифмическая регрессия	5.600	64.72	0.013	0.529
Метод K ближайших соседей	2.965	22.41	0.005	0.837
Дерево решений	3.824	39.04	0.008	0.716
Случайный лес	2.761	18.65	0.004	0.865
Градиентный бустинг	2.702	17.31	0.004	0.874
Многослойный персепtron	3.909	32.30	0.007	0.765
Ассоциативная регрессия	3.027	20.42	0.004	0.851
Ассоциативная регрессия с регуляризацией	3.209	24.61	0.005	0.821
Кластерная ассоциативная регрессия	4.066	34.92	0.008	0.746
Мультимодальная ассоциативная регрессия	3.893	33.77	0.007	0.759

Идентификация сегодня

Методы построения интеллектуальных предиктивных моделей нелинейных нестационарных систем на основе ассоциативного поиска и вейвлет-анализа

$$\begin{aligned} x(t) &= \sum_{k=1}^N c_{L,k}^x(t) \varphi_{L,k}(t) + \sum_{l=1}^L \sum_{k=1}^N d_{l,k}^x(t) \psi_{l,k}(t), \\ y(t) &= \sum_{k=1}^N c_{L,k}^y(t) \varphi_{L,k}(t) + \sum_{l=1}^L \sum_{k=1}^N d_{l,k}^y(t) \psi_{l,k}(t), \end{aligned} \quad (2.17)$$

где $\varphi_{L,k}(t)$ – масштабирующие функции; $\psi_{l,k}(t)$ – вейвлет-функции, которые получаются из материнских вейвлетов посредством масштабирования и сдвига:

$$\psi_{l,k}(t) = 2^{l/2} \psi_{\text{mother}}(2^l t - k) \quad (2.18)$$

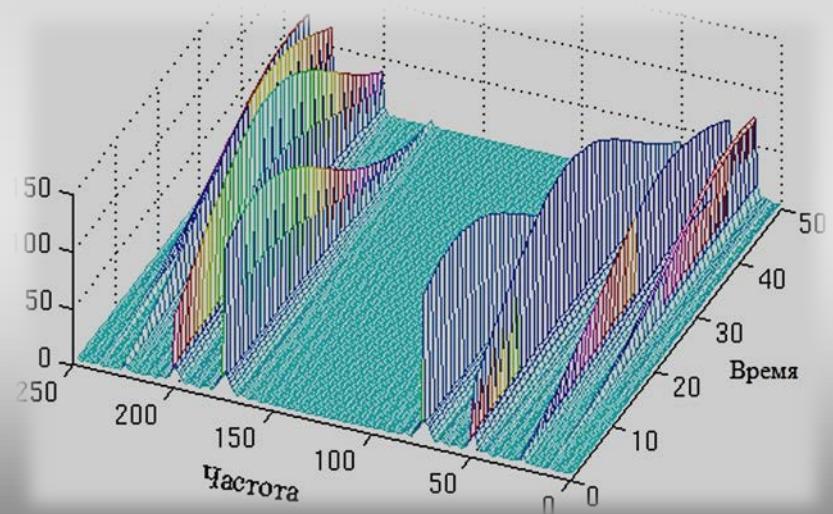
В качестве материнских рассматриваются вейвлеты Хаара. l – уровень детализации; $c_{L,k}$ – масштабирующие коэффициенты, $d_{l,k}$ – детализирующие коэффициенты. Коэффициенты вычисляются с помощью алгоритма Малла [2.86].

Выбор входных векторов из базы индуктивных знаний осуществляется в соответствии с требованием:

$$\begin{aligned} |x(t^*) - x(t)| &\leq |x(t^*)| + |x(t)| = \left| \sum_{k=1}^{2^L} c_k^* \varphi_k(t^*) + \sum_{j=1}^L \sum_{k=1}^{2^j} d_{jk}^* \psi_{jk}(t^*) \right| + \\ &+ \left| \sum_{k=1}^{N/2^L} c_k \varphi_k(t) + \sum_{j=1}^L \sum_{k=1}^{N/2^j} d_{jk} \psi_{jk}(t) \right| \leq \left| \sum_{k=1}^{2^L} c_k^* \varphi_k(t^*) \right| + \left| \sum_{k=1}^{2^L} c_k \varphi_k(t) \right| + \\ &+ \sum_{j=1}^L \left| \sum_{k=1}^{N/2^j} d_{jk} \psi_{jk}(t) \right| + \sum_{j=1}^L \left| \sum_{k=1}^{N/2^j} d_{jk}^* \psi_{jk}(t^*) \right| \leq c_L + L \tilde{c}_j = C = \text{const} > 0. \end{aligned}$$

$$\tilde{c}_j = \frac{N}{2^{j-1}} \max_{k=1, \dots, N/2^j} \tilde{c}_{jk}. \quad (2.19)$$

Исследуются кратномасштабные вейвлет-разложения входов и выходов





Метод поиска ассоциативных правил

Association Rule Mining — метод анализа данных, направленный на выявление скрытых закономерностей и **связей между переменными в больших наборах данных**.

Результат работы метода представляется в виде правила

$X \Rightarrow Y$, где **появление набора элементов X влечет за собой появление Y**.

Метрики оценки силы правил:

Поддержка (Support): частота, с которой набор элементов встречается в общей массе транзакций.

Достоверность (Confidence): вероятность того, что при наличии X «в корзине» окажется и Y.

Лифт (Lift): коэффициент «интересности» правила, показывающий, насколько чаще X и Y покупаются вместе по сравнению с тем, если бы они были независимы.

Метод поиска ассоциативных правил

Существуют проблемы:

- коррелированность архивных и текущих переменных входов, выходов и управляющих воздействий для модели,
- скрытые («латентные») статистические зависимости между переменными, определяющими состояние процесса, и дополнительными не учтенными внешними факторами.

Метод поиска ассоциативных правил не требует описывать и учитывать в явном виде статистическую зависимость между переменными.

Пусть для фиксированного момента времени t для конкретной операции j имеются исследуемые наборы элементов $R = \{r_i\}, i = 1, \dots, K$.

Эти наборы, дополненные идентификаторами $\langle I_1 \rangle \stackrel{\text{def}}{=} \langle ijt \rangle$, называются *транзакциями*:

$$T_j(t) = \{r_{ij}(t+1) \mid r_{ij}(t) \in R, I_{1j}\}, T = \{T_j(t), j = 1, \dots, m; t = 0, 1, \dots, t_j\}.$$

Ассоциативное правило состоит из двух наборов, которые называют, соответственно, *условие* (antecedent) и *следствие* (consequent), связанных отношением «из X следует Y » **Ассоциативное правило представляет собой импликацию $X \Rightarrow Y$** ,



Метод поиска ассоциативных правил

Алгоритмы

Apriori: самый известный алгоритм, основанный на принципе: если набор элементов встречается часто, то и все его подмножества тоже встречаются часто.

FP-Growth (Frequent Pattern Growth): более быстрый современный метод, который строит компактное дерево связей (FP-tree), избавляя от необходимости многократного сканирования базы данных.

AIS: один из первых алгоритмов, работающий путем генерации кандидатов-правил во время сканирования данных.

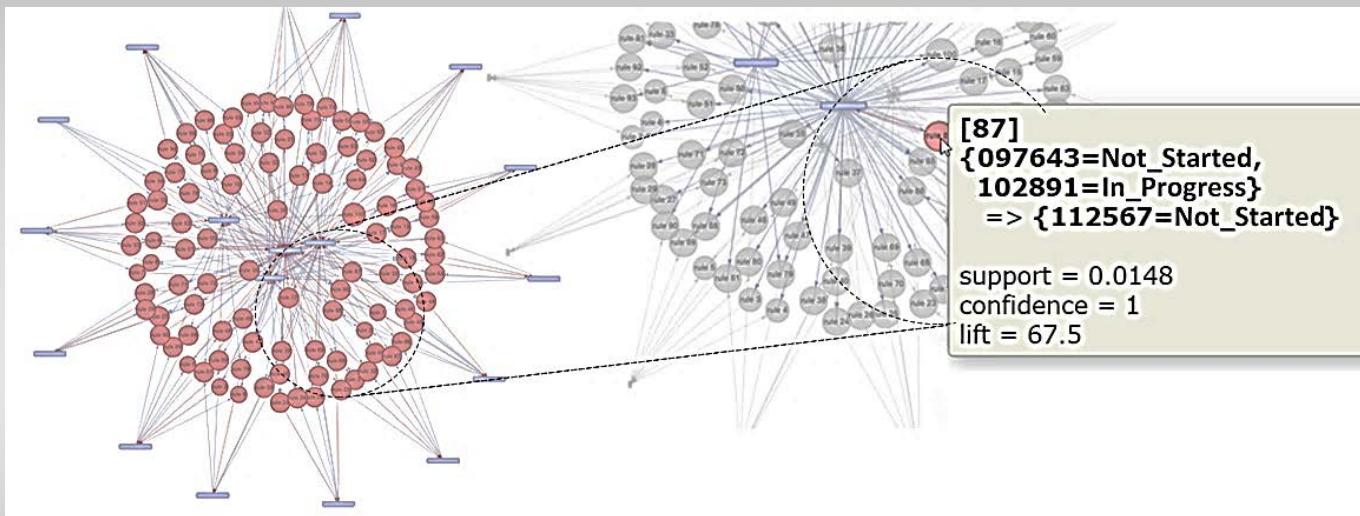
Процесс поиска

- Нахождение часто встречающихся наборов: отбор комбинаций элементов, поддержка которых выше заданного порога (minsupport).
- Генерация правил: создание ассоциаций из найденных наборов, чья достоверность выше минимального порога (minconfidence).

Метод поиска ассоциативных правил Прогнозирование

Рассматриваем в качестве X - текущий набор значений, а в качестве Y – набор этих значений в последующий момент времени.

Правило: если в транзакции встретился некоторый набор элементов X (состоящий из нулей и единиц), то на основании этого можно сделать вывод о том, что в следующий момент времени должен появиться определенный набор элементов Y .



Прогноз **состояния, интерпретируемого булевой цепочкой**, может быть получен на основе **выявления наиболее вероятного сочетания двух бинарных наборов**: в фиксированный момент времени и в момент, следующий за ним (предсказание на один шаг).

Прогнозирование для динамических процессов методом ассоциативного поиска

$x_1 = x(t_1)$	$x_2 = x(t_2)$	$x_3 = x(t_3)$
$x_1 \in Q_{i1}$	$x_2 \in Q_{j2}$	$x_3 \in Q_{m3}$
$i \in \{1, \dots, 5\}$	$j \in \{1, \dots, 5\}$	$m \in \{1, \dots, 5\}$

Фрагмент видеопотока с видеокамер, установленных на фурмах доменной печи



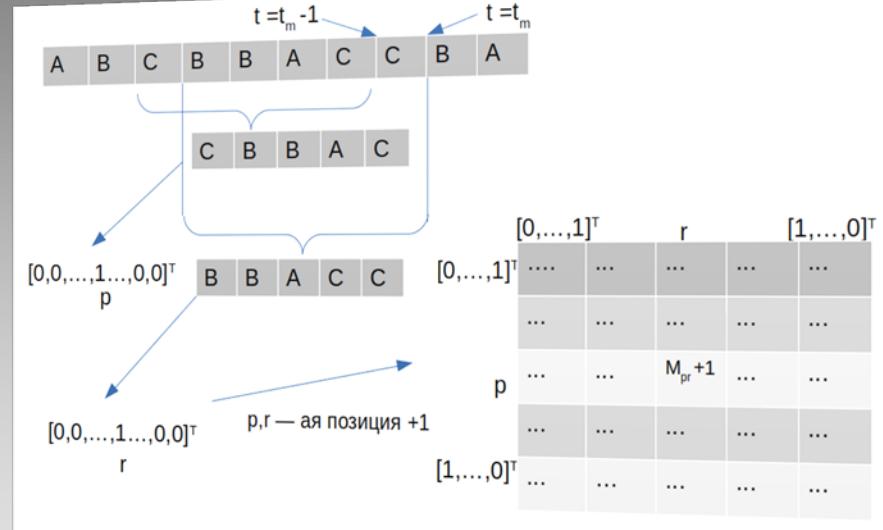
очень быстрое движение средних и крупных фрагментов с большим перепадом контрастности изображения.



Описание динамики:
быстрое движение крупных и средних фрагментов средней интенсивности с малым перепадом контрастности



движение средних фрагментов средней скорости с малым перепадом контрастности изображения.



«Типовые» технологические ситуации:

- мельтешение шихты;
- затухание фурменного очага;
- оползание гарнисажа;
- образование шлака;
- появление инородного тела.

Сценарное прогнозирование для динамических процессов методом ассоциативного поиска

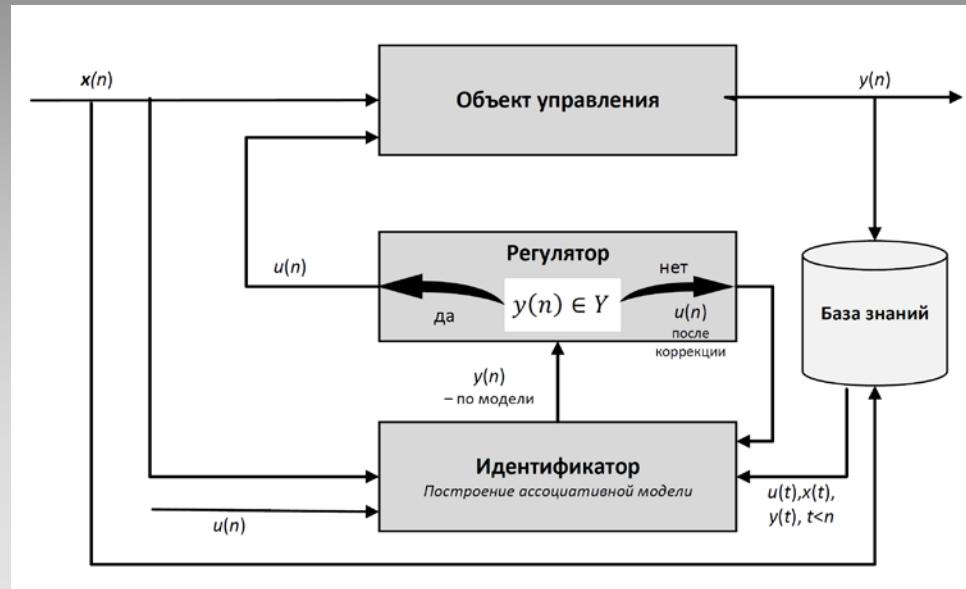
Номера цепочек кластерных меток, предшествующие моментам $n - n + 9$

n	$n+1$	$n+2$	$n+3$	$n+4$	$n+5$	$n+6$	$n+7$	$n+8$	$n+9$
A	B	B	B	A	A	C	C	D	A
			ABBB	BBBA	BBA	BAAC	AACC	ACCD	CCDA
			1	2	3	4	5	6	7

Произвольная цепочка $y(n), y(n + 1), \dots, y(n + T - 1)$ может быть представлена в виде «вектора состояния», где единица стоит только в той позиции, которая по номеру совпадает с порядковым номером этой цепочки, а в остальных местах стоят нули. Например, для записи с помощью символов алфавита A, ..., Z цепочка AAAA будет иметь запись $\vec{s} = [0, 0, 0, \dots, 0, 1]$.

Управление на основе ассоциативных предиктивных моделей реального времени

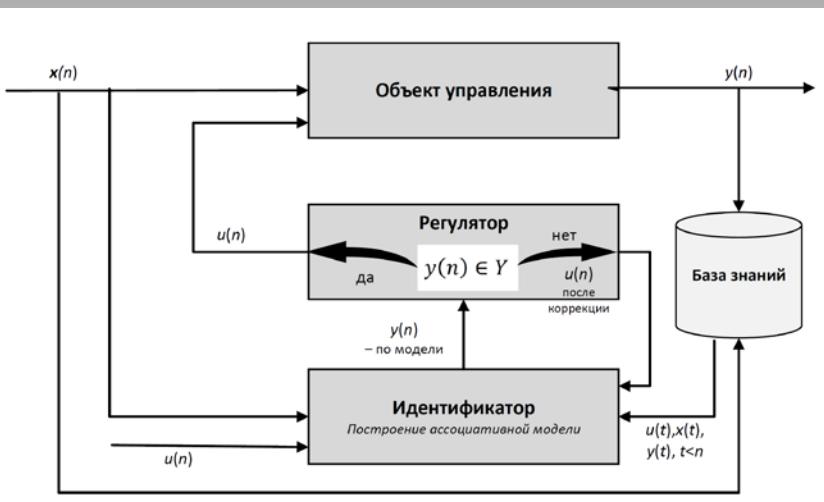
- Формируется «расширенный вектор входов» - из значений входов, предыдущих выходов, управлений
- Решается задача ассоциативного поиска с применением методов регуляризации



**Идентификатор системы управления –
цифровой двойник**

$$y(n) = \sum_{k=0}^{n-1} \sum_{i=1}^M a_{ik} x_i(n-k) + \sum_{r=1}^{n-1} c_r u(n-r) + c_n u(n) + \sum_{j=1}^{n-1} b_j y(n-j)$$

Оптимальное и субоптимальное управление на основе ассоциативных предиктивных моделей реального времени

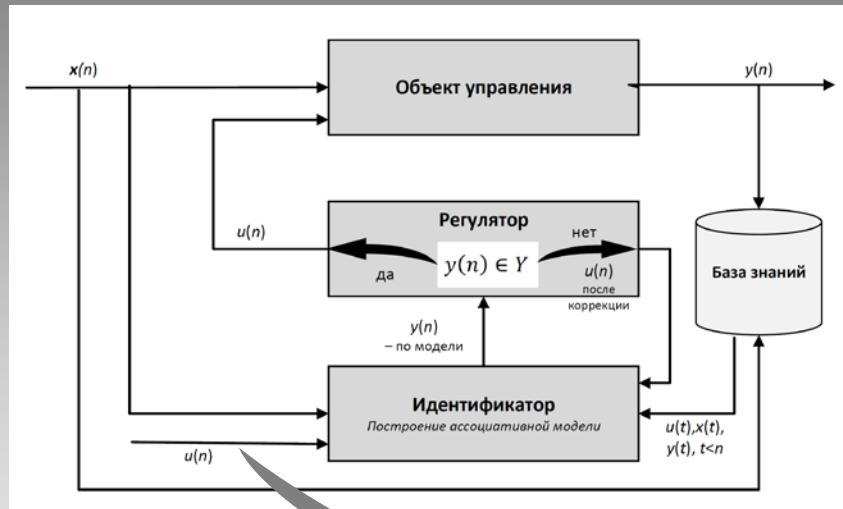


$$y_{opt} = \sum_{k=0}^{n-1} \sum_{i=1}^M a_{ik} x_i(n-k) + \sum_{r=1}^{n-1} c_r u(n-r) + c_n u(n) + \sum_{j=1}^{n-1} b_j y(n-j)$$

Алгоритмы сценарного моделирования выхода системы управления

Предложен алгоритм формирования управления с учетом ограничений на значения выходов системы и управляемых воздействий:

$$|y| \leq Y, |u| \leq U, Y, U > 0.$$



$$y(n) = \sum_{k=0}^{n-1} \sum_{i=1}^M a_{ik} x_i(n-k) + \sum_{r=1}^{n-1} c_r u(n-r) + c_n u(n) + \sum_{j=1}^{n-1} b_j y(n-j)$$

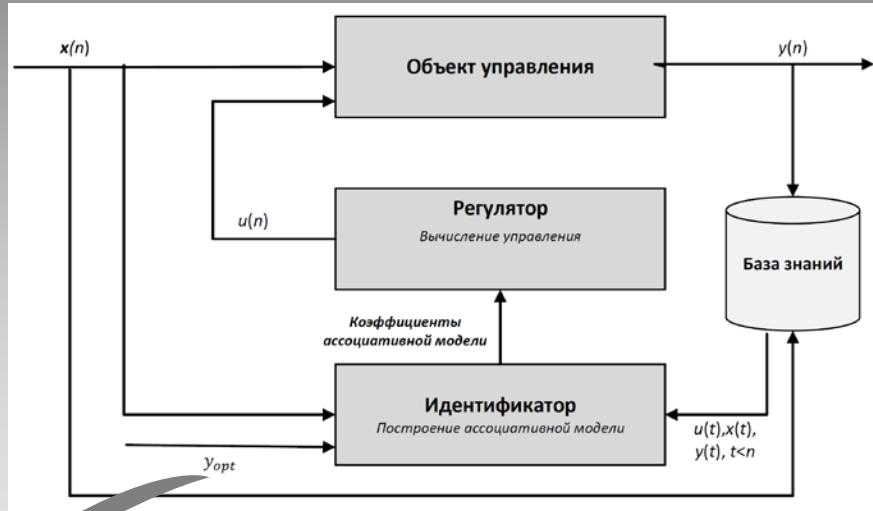
Расширенный вектор входов из трех групп компонентов:

- значений входов $x_j(q)$, где $q \in [n+1-M, n], j \in [1, M]$;
- значений управления $u(r)$, где $r \in [1, K]$;
- значений выхода $y(p)$, где $p \in [n+1-N, n]$,

Алгоритмы сценарного моделирования оптимального и суб-оптимального управления

Предложен алгоритм формирования управления с учетом ограничений на значения выходов системы и управляемых воздействий:

$$|y| \leq Y, |u| \leq U, Y, U > 0.$$



$$y_{opt} = \sum_{k=0}^{n-1} \sum_{i=1}^M a_{ik} x_i(n-k) + \sum_{r=1}^{n-1} c_r u(n-r) + c_n u(n) + \sum_{j=1}^{n-1} b_j y(n-j)$$

Расширенный вектор входов из трех групп компонентов:

- значений входов $x_j(q)$, где $q \in [n+1-M, n], j \in [1, M]$;
- значений управления $u(r)$, где $r \in [1, K]$;
- значений выхода $y(p)$, где $p \in [n+1-N, n]$,

Методы идентификации **ситуаций** и прогнозирования состояния комплекса ресурсов предприятий и компаний. Прогнозирование нештатных ситуаций

Совокупность значений признаков

- **цифровой портрет ситуации**

1. Состояние производственного процесса

Ассоциативный поиск (*just in time*)
предиктивные цифровые
идентификационные модели –

2. Прогноз состояния комплекса гетерогенных ресурсов

Метод ассоциативных правил

- Оборудование
- Вычислительные ресурсы
- Человеческие ресурсы
- Внешние факторы

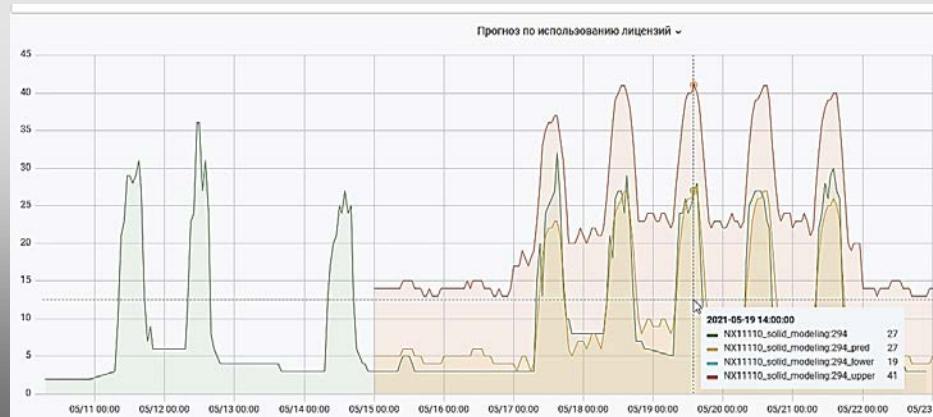
**Признаки, описывающие
состояние гетерогенных
ресурсов:**

3. Режим функционирования
4. Внешние факторы

- численные (значения различных характеристических показателей)
- категориальные
- нечеткие
- «работает» – «не работает»
- ...

Моделирование **ситуаций**: прогнозирование состояния комплекса гетерогенных ресурсов и Прогноз нештатных ситуаций

- Оценка текущего состояния производственных ресурсов и его прогнозирование - с целью **предвидения ситуаций**, при которых выполнение плана становится проблематичным либо невозможным.
- Выявить скрытую статистическую взаимосвязь между состоянием различных ресурсов на разных временных шагах без предварительного статистического анализа.
- При этом могут быть рассмотрены **не только технологические процессы**, но и процессы оперативного управления производством, планирование ресурсов, и т.д.
- ...



Сценарное прогнозирование ситуаций: состояния комплекса гетерогенных ресурсов и прогноз нештатных ситуаций

Алгоритмы сценарного прогнозирования эволюции технологических ситуаций.

Возможность раннего предупреждения наступления нештатных ситуаций

Предупреждение ситуаций, при которых выполнение плана становится проблематичным либо невозможным

Алгоритм сценарного прогнозирования производственной ситуации

Для описания состояния каждого из факторов, используемых в модели, используются метки кластеров, в которые значения этих кластеров попадают в момент n . В каждый момент времени для описания ситуации будем использовать не только соответствующую кластерную метку, но и ее историю на предыдущих временных интервалах.

n	$n+1$	$n+2$	$n+3$	$n+4$	$n+5$	$n+6$	$n+7$	$n+8$	$n+9$
A	B	B	B	A	A	C	C	D	A
			ABBB	BBBA	BBA	BAAC	AACC	ACCD	CCDA
				1	2	3	4	5	6

Предположим, что имеется некоторый порядок нумерации возможных цепочек. Тогда, если длина цепочки равна T , а алфавит кластерных меток имеет длину l , то общий размер пространства равен $N_c = l^T$ элементов. Произвольная цепочка значений может быть представлена в виде вектора состояния размерности N_c , где единица стоит только в той позиции, которая по номеру совпадает с порядковым номером этой цепочки, а в остальных местах стоят нули. Например, для записи с помощью символов алфавита A, ..., Z цепочка AAAA будет иметь запись $\vec{s} = [0,0,0,\dots,0,1]$.

n	$n+1$	$n+2$	$n+3$	$n+4$	$n+5$	$n+6$	$n+7$	$n+8$	$n+9$
A	B	B	B	A	A	C	C	D	A
			ABBB	BBBA	BBA	BAAC	AACC	ACCD	CCDA
				1	2	3	4	5	6



Разработка алгоритмов управления в условиях неопределенности внешних факторов, учитывающих особенности ситуационных изменений

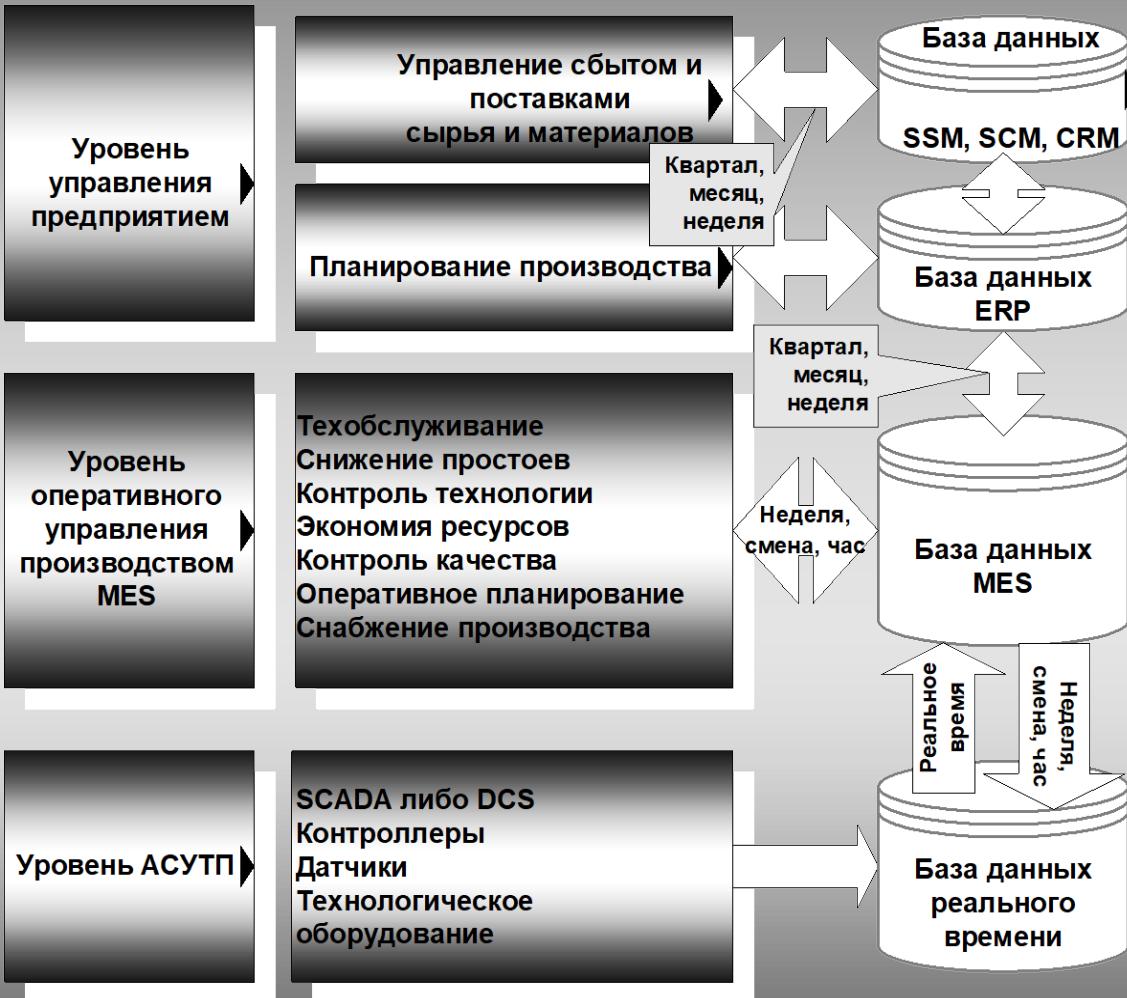
Управление производственным процессом в условиях неопределенности внешних факторов может быть интерпретировано как управление ситуацией с помощью сценарного моделирования.

Предложены методы управления производственной ситуацией в условиях неопределенностей внешних факторов, прежде всего – состояний производственных ресурсов различных типов.

Актуальной является разработка процедур проактивного управления в условиях, когда неизвестно, как конкретно изменится ситуация, например:

- время выполнения определенной технологической операции, если на предыдущем шаге произошла, в силу определенных причин, замена оператора на менее квалифицированного.
- произошел нештатный сбой программного обеспечения определенного типа, что повлекло за собой не только нештатное использование резервов и коррекцию производственного расписания, но и сбои на других участках, и т.д.

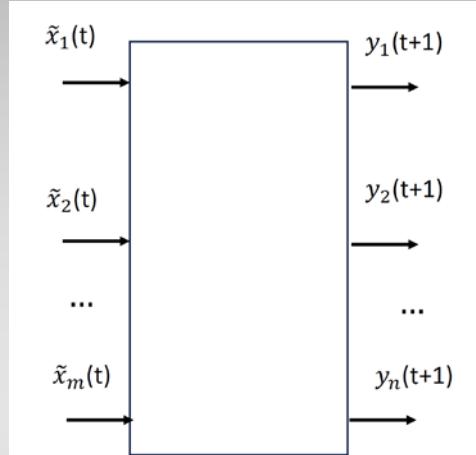
Методы управления сложными структурами на основе цифровых предиктивных моделей реального времени



- Интегрированная система управления производственным процессом промышленного предприятия (управление технологическими процессами, оперативное управление производством (MES) и производственная логистика, управление ресурсами и взаимоотношениями с поставщиками и потребителями)
- Система управления цепочками поставок
- Оптимальная маршрутизация мультимодальных грузоперевозок
- Сценарное моделирование и оптимальное управление

Методы разработки цифровых предиктивных моделей производственных процессов для сложных производственных структур

1. Алгоритм предиктивного управления многомерной системой

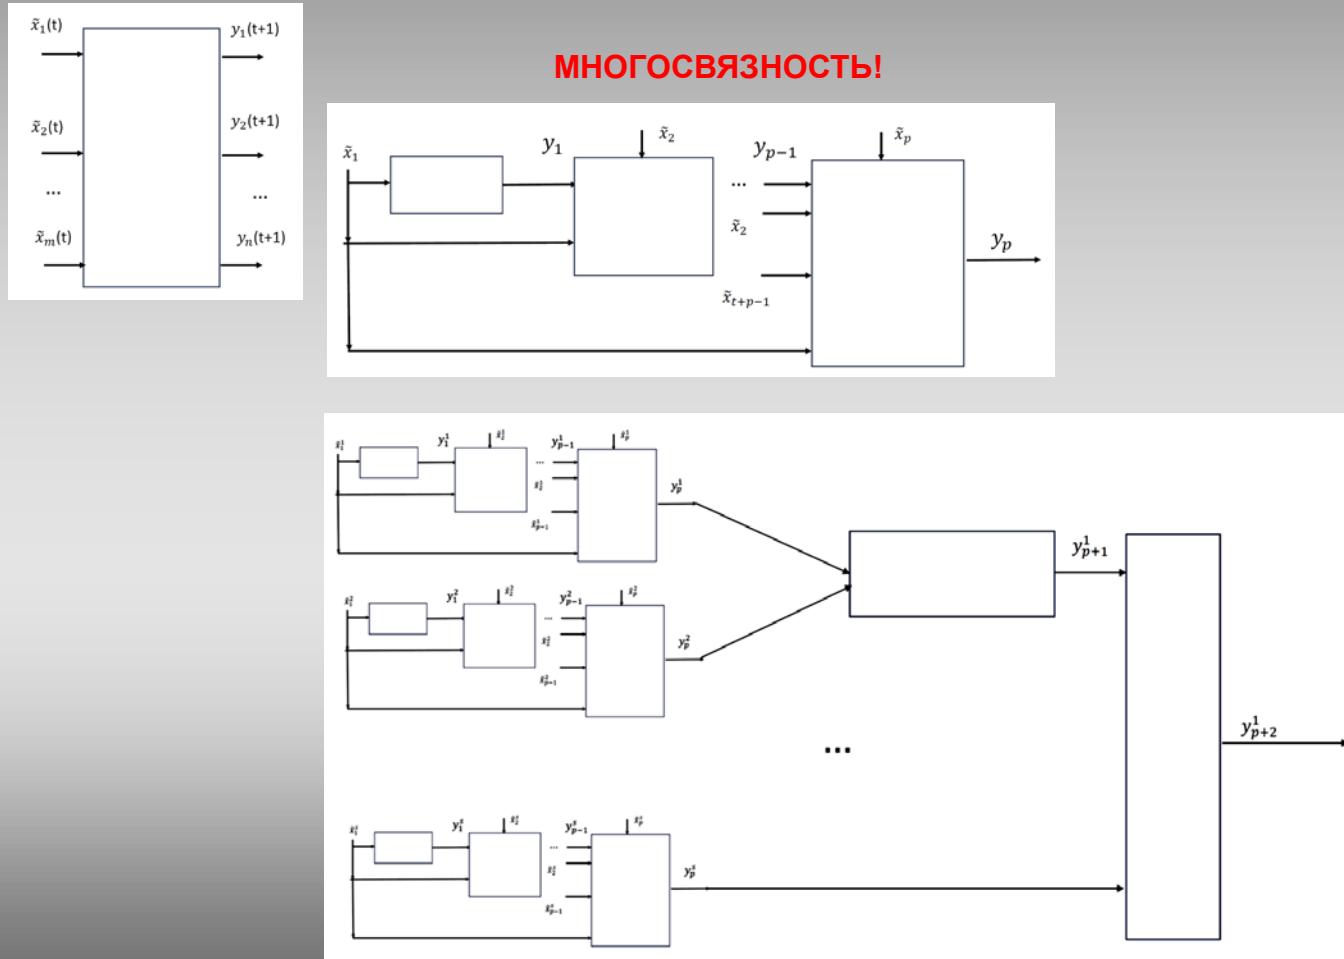


$$\left\{ \begin{array}{l} y_1(n) = \sum_{i=1}^{k_1} \alpha_i^1 \tilde{x}_i^1(n-1) + \sum_{i=1}^{m_1} \beta_i^1 u_i^1(n-1), \\ y_2(n) = \sum_{i=1}^{k_2} \alpha_i^2 \tilde{x}_i^2(n-1) + \sum_{i=1}^{m_2} \beta_i^2 u_i^2(n-1), \\ \dots \\ y_p(n) = \sum_{i=1}^{k_p} \alpha_i^p \tilde{x}_i^p(n-1) + \sum_{i=1}^{m_p} \beta_i^p u_i^p(n-1). \end{array} \right.$$

Расширенный вектор входов многомерной модели составлен из векторов $\tilde{x}_i^i, i \in 1, \dots, p$.

Методы разработки цифровых предиктивных моделей производственных процессов для сложных производственных структур

2. Разные типы схем сложных систем



Для каждой подсистемы формируется своя процедура ассоциативного поиска.

Все «прецеденты», набираемые из БЗ, различны для каждой из подсистем, даже если модели содержат одни и те же переменные



Процедура Мура–Пенроуза для построения моделей ассоциативного поиска при зависимых входах

Задача определения оценок неизвестных параметров множественной линейной регрессии может быть сведена к вычислению псевдо-решения переопределенной системы линейных алгебраических уравнений (СЛАУ).

Процедура Мура–Пенроуза определения неизвестных коэффициентов линейной динамической модели:

$$y_N = \sum_{i=1}^Q \alpha_i \hat{x}_i,$$

где $\hat{x} = (\hat{x}_1, \hat{x}_2 \dots \hat{x}_r), r = m + nS$, \hat{x} – расширенный вектор входов, для которого:

$$\{\hat{x}_1, \hat{x}_2, \dots, \hat{x}_m\} = \{y_{N-1}, y_{N-2}, \dots, y_{N-m}\};$$

$$\{\hat{x}_{m+1}, \hat{x}_{m+2} \dots \hat{x}_{m+nS}\} = \{x_{N-1,1}, x_{N-1,2}, \dots, x_{N-1,S}, \dots, x_{N-n,S}\};$$

α – расширенный вектор коэффициентов:

$$\{\alpha_1, \alpha_2, \dots, \alpha_m\} = \{a_1, a_2, \dots, a_m\};$$

$$\{\alpha_{m+1}, \alpha_{m+2}, \dots, \alpha_{m+nS}\} = \{b_{1,1}, b_{1,2}, \dots, b_{1,S}, \dots, b_{n,S}\}.$$

выбираются входные векторы, близкие к текущему в смысле евклидового расстояния.

Процедура Мура–Пенроуза для построения моделей ассоциативного поиска при зависимых входах

После отбора векторов из архива исторических данных ТП составляется матрица расширенных

векторов входов:

$$\widehat{\mathbf{X}} = \begin{pmatrix} \widehat{x}_1^1 & \dots & \widehat{x}_r^1 \\ \vdots & \ddots & \vdots \\ \widehat{x}_1^P & \dots & \widehat{x}_r^P \end{pmatrix}, \quad P \gg r.$$

Для нахождения коэффициентов α_i модели необходимо решить систему линейных уравнений вида:

$$\widehat{\mathbf{X}}\alpha = \widehat{y},$$

Если матрица $\widehat{\mathbf{X}}$ полного ранга, т.е. $\text{rank } \widehat{\mathbf{X}} = r$, то при решении задачи применяется МНК для нахождения оценки $\widehat{\alpha}$:

$$(\widehat{y} - \widehat{\mathbf{X}}\widehat{\alpha})^T (\widehat{y} - \widehat{\mathbf{X}}\widehat{\alpha}) = \min_{\alpha} (\widehat{y} - \widehat{\mathbf{X}}\alpha)^T (\widehat{y} - \widehat{\mathbf{X}}\alpha).$$

Необходимое условие минимума по α приводит к системе линейных алгебраических уравнений:

$$\widehat{\mathbf{X}}^T \widehat{\mathbf{X}} \alpha = \widehat{\mathbf{X}}^T \widehat{y}. \tag{1.6}$$

В предположении, что $\widehat{\mathbf{X}}$ – матрица полного ранга, получаем:

$$\widehat{\alpha} = (\widehat{\mathbf{X}}^T \widehat{\mathbf{X}})^{-1} \widehat{\mathbf{X}}^T \widehat{y}. \tag{1.7}$$

$\widehat{\alpha}$ является МНК-оценкой и, согласно теореме Гаусса-Маркова, обладает минимальной дисперсией в классе несмешанных линейных оценок параметра α .



Процедура Мура—Пенроуза для построения моделей ассоциативного поиска при зависимых входах и регуляризация

Ограничение: процедура Мура — Пенроуза чувствительна к малым возмущениям данных.

Если в данных есть шум, малые сингулярные числа матрицы могут привести к резкому росту ошибки (неустойчивости).

Регуляризация применяется:

- в некорректно поставленных задачах, где данные содержат шум или матрица плохо обусловлена (сингулярные числа матрицы очень малы, близка к вырожденной),
- для предотвращения переобучения, накладывается штраф на сложность модели.

При стремлении параметра регуляризации к нулю решение сходится к нормальному псевдорешению Мура — Пенроуза



Метод локальной регуляризации для алгоритма ассоциативного поиска

Метод осуществляет подбор параметров регуляризации в зависимости от свойств обучающей выборки на текущем временном такте.

1. На вход алгоритма подаётся текущий вектор входных данных, требуется рассчитать прогнозируемый выход;
2. из базы знаний отбирается достаточное число «близких» входных векторов и соответствующих им выходов. В результате формируется матрица известных входов \hat{X} и соответствующий ей вектор выходов \hat{y} ;
3. рассчитывается число обусловленности информационной матрицы ТП $\hat{X}^T \hat{X}$.

Если $cond(\hat{X}^T \hat{X}) < threshold$ – переход к пункту 5 и рассчитывается ω при $\lambda = 0$;

4. рассчитывается параметр регуляризации $\lambda = \frac{\hat{\sigma}_{max} - threshold * \hat{\sigma}_{min}}{threshold - 1}$, где $\hat{\sigma}_{max}$ и $\hat{\sigma}_{min}$ – максимальное и минимальное собственные числа матрицы $\hat{X}^T \hat{X}$ соответственно;
5. рассчитываются коэффициенты модели $\omega = (\hat{X}^T \hat{X} + \lambda I)^{-1} \hat{X}^T \hat{y}$;
6. рассчитывается прогноз выхода.



Методы управления производственными ситуациями на основе цифровых предиктивных моделей

Применяем процедуру поиска ассоциативных правил.

В качестве X будем рассматривать конкатенацию следующих бинарных цепочек:

- a) номер кластера, в который попал текущий расширенный вектор входов (включающий в управление $u(t)$);
- b) бинарная маска структуры модели в момент $t - 1$ (если соответствующий фактор содержится в модели системы, и 0 – в противном случае);
- c) номер кластера, в который попал вектор коэффициентов модели в момент $t - 1$;
- d) факторы, дополнительно характеризующие производственную ситуацию.

Например, эта часть цепочки X может отражать состояние комплекса гетерогенных ресурсов.

- e) формализованные ограничения. Например, номер кластера, в который должен попасть выход системы. Также можно кластеризовать длительность выполнения задачи текущей подсистемы и отражать номер кластера, в который должно попасть это значение.

В качестве Y для текущих данных входа, управления и структуры модели в момент $t - 1$ будем рассматривать конкатенацию бинарных цепочек, состоящую из следующих фрагментов:

- f) бинарную маску структуры модели в момент t ;
- g) бинарный номер кластера, в который попадет вектор коэффициентов модели в момент t ;
- h) номер кластера, в который попадает выход системы.

Описание системы в цифровом пространстве состояний:

a) Выход при заданном управлении:



в) Рекомендуемое управление для получения желаемого выхода:





Применение разработанных методов в схеме управления ТП с прогнозирующей моделью

На производстве сегодня применяются:

- Классические методы ПИД-регулирования,
- «расширенное регулирование» (каскады ПИД-регуляторов, компенсаторы, управление отношением, управление с опережением

- МРС (Предиктивное управление на основе модели):

Строит математическую модель процесса, предсказывает его будущее поведение, **вычисляет оптимальный набор управляющих действий на выбранном горизонте прогнозирования** и применяет только первое из них.

Преимущества: учет ограничений, проактивность, хорошо справляется с многомерными задачами, запаздыванием.

Реализация: Может быть реализовано как на уровне систем распределенного управления (DCS), так и на уровне отдельных компьютеров.

Управление с прогнозирующей моделью ТП (Model Predictive Control - MPC)

Применяется для управления сложными системами с ограничениями

- **Нефтепереработка:** Управление дистилляционными колоннами, печами, котлами и процессами смешивания.
- **Энергетика:** Управление потоками энергии, балансировка энергосистем, управление генерацией и распределением Умные энергосети (Smart Grids): распределенное MPC (DMPC) для интеграции возобновляемых источников и оптимизации работы инверторов в сетях.
- **Силовая электроника:** Управление преобразователями. Предиктивное управление током и крутящим моментом (MPCC/MPTC) в электродвигателях, позволяющее обходиться без классических модулей модуляции
- **Автоматизация:** Управление производственными линиями.
- **Строительные системы:** Интеллектуальное управление отоплением, вентиляцией и кондиционированием (HVAC) на основе прогнозов погоды для минимизации энергопотребления
- **Робототехника и автоматизированный транспорт:** планирование движения, ограничение скорости, безопасное расстояние, автономное вождение)

Управление с прогнозирующей моделью ТП (Model Predictive Control - MPC)

- **Транспорт и робототехника:**

- **Беспилотный транспорт:** MPC используется для генерации траекторий и уклонения от препятствий в автономных мобильных роботах (AMR) и беспилотных автомобилях.
- **Аэрокосмическая отрасль:** Управление сложной динамикой вертолетов и других летательных аппаратов.
- **Автономное судоходство:** Интеграция MPC с большими языковыми моделями (LLM) для адаптивного управления курсом морских судов.
- **Железнодорожный транспорт:** Оптимизация следования городских поездов по расписанию

Алгоритм Model Predictive Control - MPC

Измерение и оценка состояния: Получение текущего состояния системы (выходы, входы).

Прогнозирование: Используя динамическую модель объекта, предсказание будущих состояний системы на горизонте прогнозирования N .

Оптимизация: Решение задачи оптимального управления, чтобы минимизировать функцию стоимости (например, квадратичную) на горизонте N , учитывая ограничения на входы и выходы.

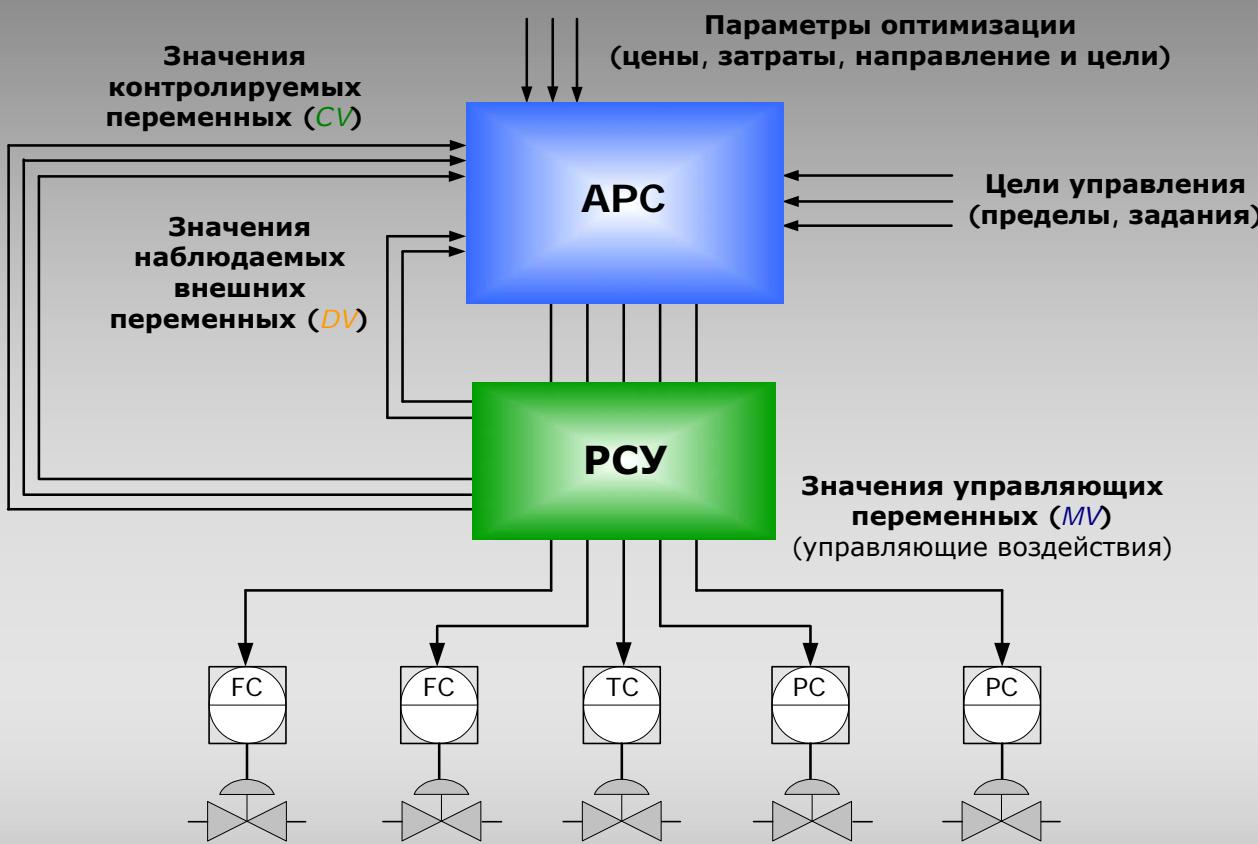
Применение управления: Применение **только первого рассчитанного управляющего воздействия $u(0)$** к системе.

Сдвиг горизонта: Повторение шагов 1-4 на следующем временном шаге (скользящее окно/горизонт).

Горизонт прогнозирования (Prediction Horizon): Временной интервал, на который делается прогноз.

Горизонт управления (Control Horizon): Временной интервал, на котором ищутся управляющие воздействия.

МРС в схеме систем усовершенствованного управления (СУУП, или APC - Advanced Process Control)

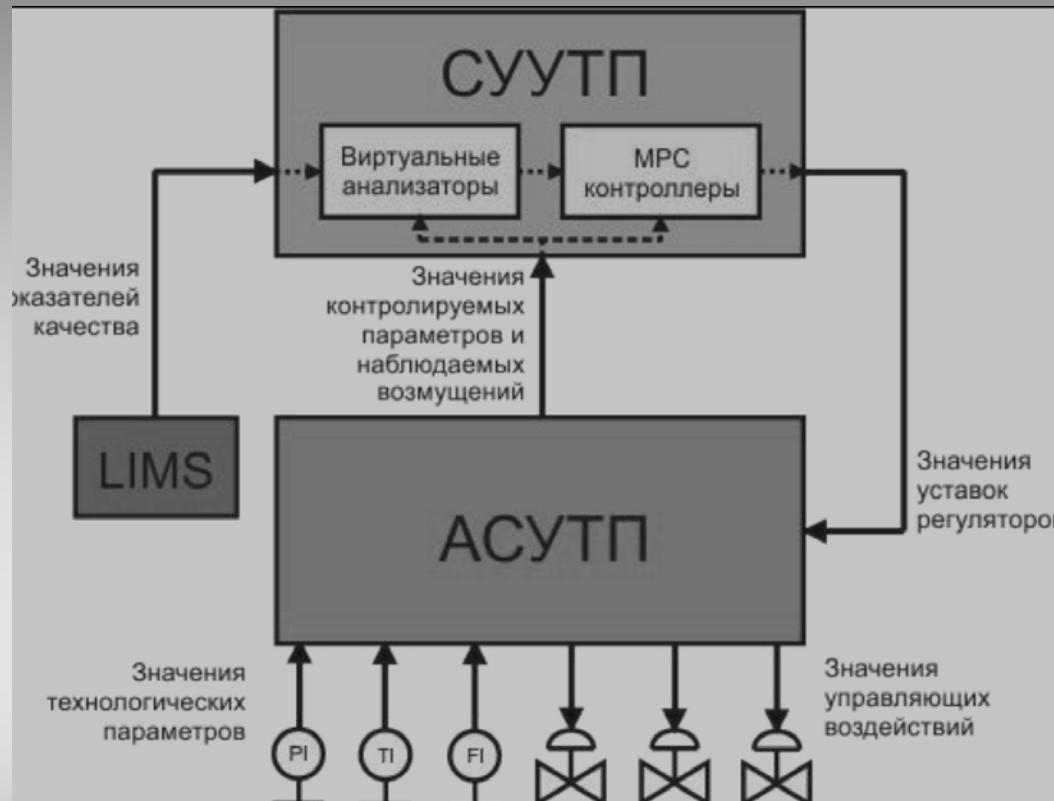


МРС-контроллер в схеме APC располагается над уровнем базовой автоматизации (ПИД-регуляторов) и выполняет роль многопараметрического регулятора (MIMO), координируя сразу несколько входов и выходов.

Это позволяет компенсировать существенные транспортные запаздывания и повысить точность регулирования на 20% и более по сравнению с классическими схемами

APC включает МРС, а также другие методы, такие как управление с упреждением (feedforward), развязывающее управление (decoupling control), инференциальное управление (inferential control) и т.д..

МРС в схеме систем усовершенствованного управления (Advanced Process Control - APC)



Воздействуя на ТП через набор управляемых переменных, APC-система следит, чтобы другие переменные ТП соответствовали требуемым заданиям (**уставкам**) или не выходили за оговоренные пределы.

На основе прогноза система, при необходимости, корректирует технологический режим, **изменяя уставки ПИД-регуляторов** приблизительно так, как их изменяет оператор.

Виртуальные анализаторы (ВА) в системах усовершенствованного управления (СУУТП, или АРС)

- математические модели, которые в режиме реального времени вычисляют значения ключевых показателей качества продукции или состояния процесса, которые невозможно либо затратно измерить напрямую или непрерывно. Их часто называют «**программными датчиками**» (*soft sensors*).

Преимущества:

Замена дорогостоящих приборов: Поточные анализаторы стоят дорого, требуют частого обслуживания и калибровки.

Устранение задержек: Лабораторные анализы могут занимать часы, а поточные датчики — десятки минут. ВА выдают результат мгновенно, позволяя системе АРС быстро реагировать на отклонения.

Непрерывность данных: ВА обеспечивают постоянный поток данных для контроллеров АРС, которые работают циклами в несколько секунд.

Принцип работы

ВА используют доступные измерения (температуру, давление, расходы), чтобы рассчитать значение целевого параметра.

Основные методы построения:

Статистические модели: Регрессионный анализ, метод главных компонентов (PCA), нейронные сети. Обучаются на исторических данных.

Детерминированные модели: Основаны на физико-химических законах (материальный и тепловой баланс).

Виртуальные анализаторы (ВА) в системах усовершенствованного управления

Методы построения

Адаптивные алгоритмы (Adaptive MPC): Обновляют модель предсказания на каждом шаге, используя новые данные, но предполагается, что модель в будущем останется неизменной.

Линейный MPC с изменяющимся во времени параметрами (LTV-MPC): Использует заранее известное изменение параметров модели во времени для более точного управления в течение всего горизонта прогноза.

MPC с планируемым усилием (Gain-Scheduled MPC): Строит несколько линеаризованных моделей для разных рабочих точек, а затем переключается между ними или интерполирует управляющие воздействия.

Нелинейный MPC (NMPC): Применяется для управления сильно нелинейными объектами, когда требуется учесть нелинейные ограничения и функции стоимости.

Регрессионные методы: Построение моделей на основе статистических зависимостей между входами и выходами. Обобщенный МНК. Линейная регрессия с подстройкой свободного члена

Нечеткий MPC (Fuzzy MPC) - модель формируется на основе нечетко-логических построений.

Нейронные сети: Использование нейронных сетей для аппроксимации сложных нелинейных функций объекта.

Применение разработанных методов в схеме управления с прогнозирующей моделью

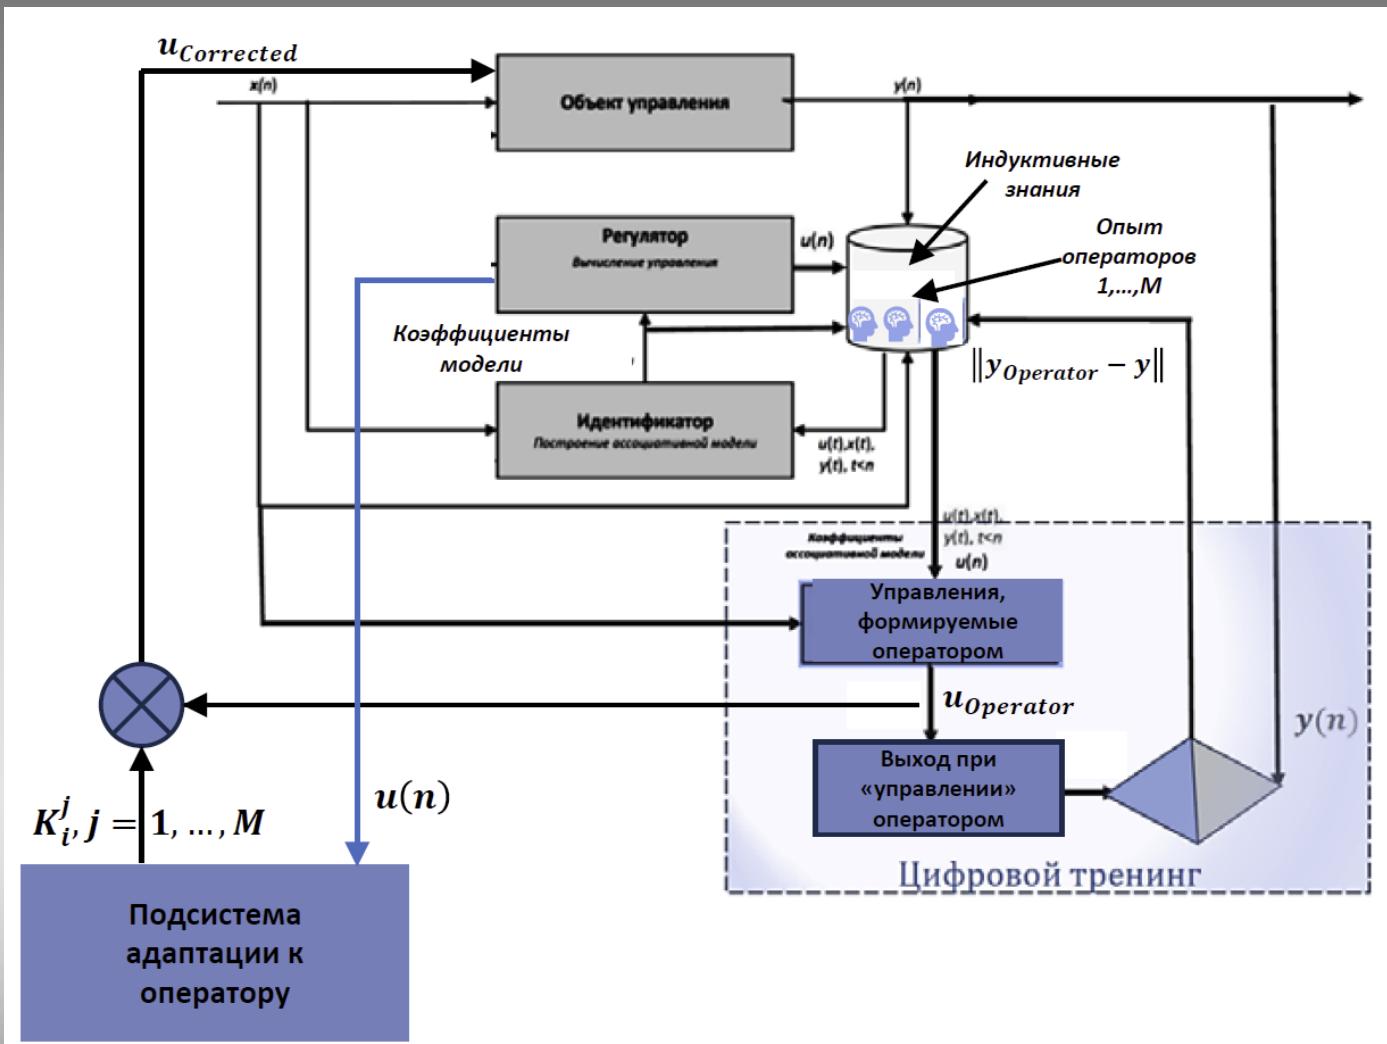
Управление ТП с прогнозирующей моделью (**Model Predictive Control - MPC**) эффективный метод управления многосвязными объектами



Применение моделей типа Ассоциативного поиска в виртуальных анализаторах MPC

Применение методов определения управляющих воздействий для формирования уставок

Интеллектуальные агенты





Спасибо за внимание!

Спасибо за внимание!