



ТИПОВЫЕ ПРОБЛЕМЫ ВНЕДРЕНИЯ ТЕХНОЛОГИЙ МАШИННОГО ОБУЧЕНИЯ В ПРОМЫШЛЕННОСТИ

Вахмянин Иван
CEO Visiology



VISIOLOGY

Аналитические решения Visiology

Аналитическая платформа Visiology

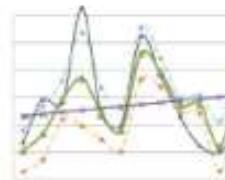
Современная платформа класса Business Intelligence для быстрого построения производительных аналитических систем для коммерческих и государственных организаций.



1. In-Memory база данных ViCube для быстрого выполнения аналитических запросов
2. Встроенная система сбора данных через настраиваемые веб-формы
3. Мощная и расширяемая система визуализации и поддержка видеостен
4. Поддержка интеграции с технологиями Big Data и Data Science
5. Полностью российская разработка



Собственный штат специалистов по Data Science



$$r_{\text{poi}} = \frac{\frac{1}{n} \sum_{i=1}^n x_i - p_i \bar{x}}{S_x \sqrt{p_i q_i}}$$

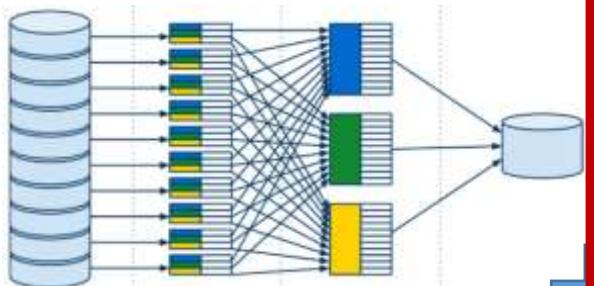
Специалисты Visiology имеют опыт работы с большими данными и имеют необходимую математическую и техническую подготовку (R, Python, Spark и т.д.), чтобы разрабатывать и внедрять решения продвинутой аналитики на основе технологий машинного обучения (Machine Learning)



VISIOLOGY

Компоненты решения Big

Data Big Data Tools



Инструменты для сбора, хранения и анализа данных, распределенных по кластерам серверов



Инженеры
Big Data



Data Science



Математические и алгоритмические методы, оптимизированные для эффективного выявления сложных закономерностей



Специалисты
Data Science



Business Intelligence



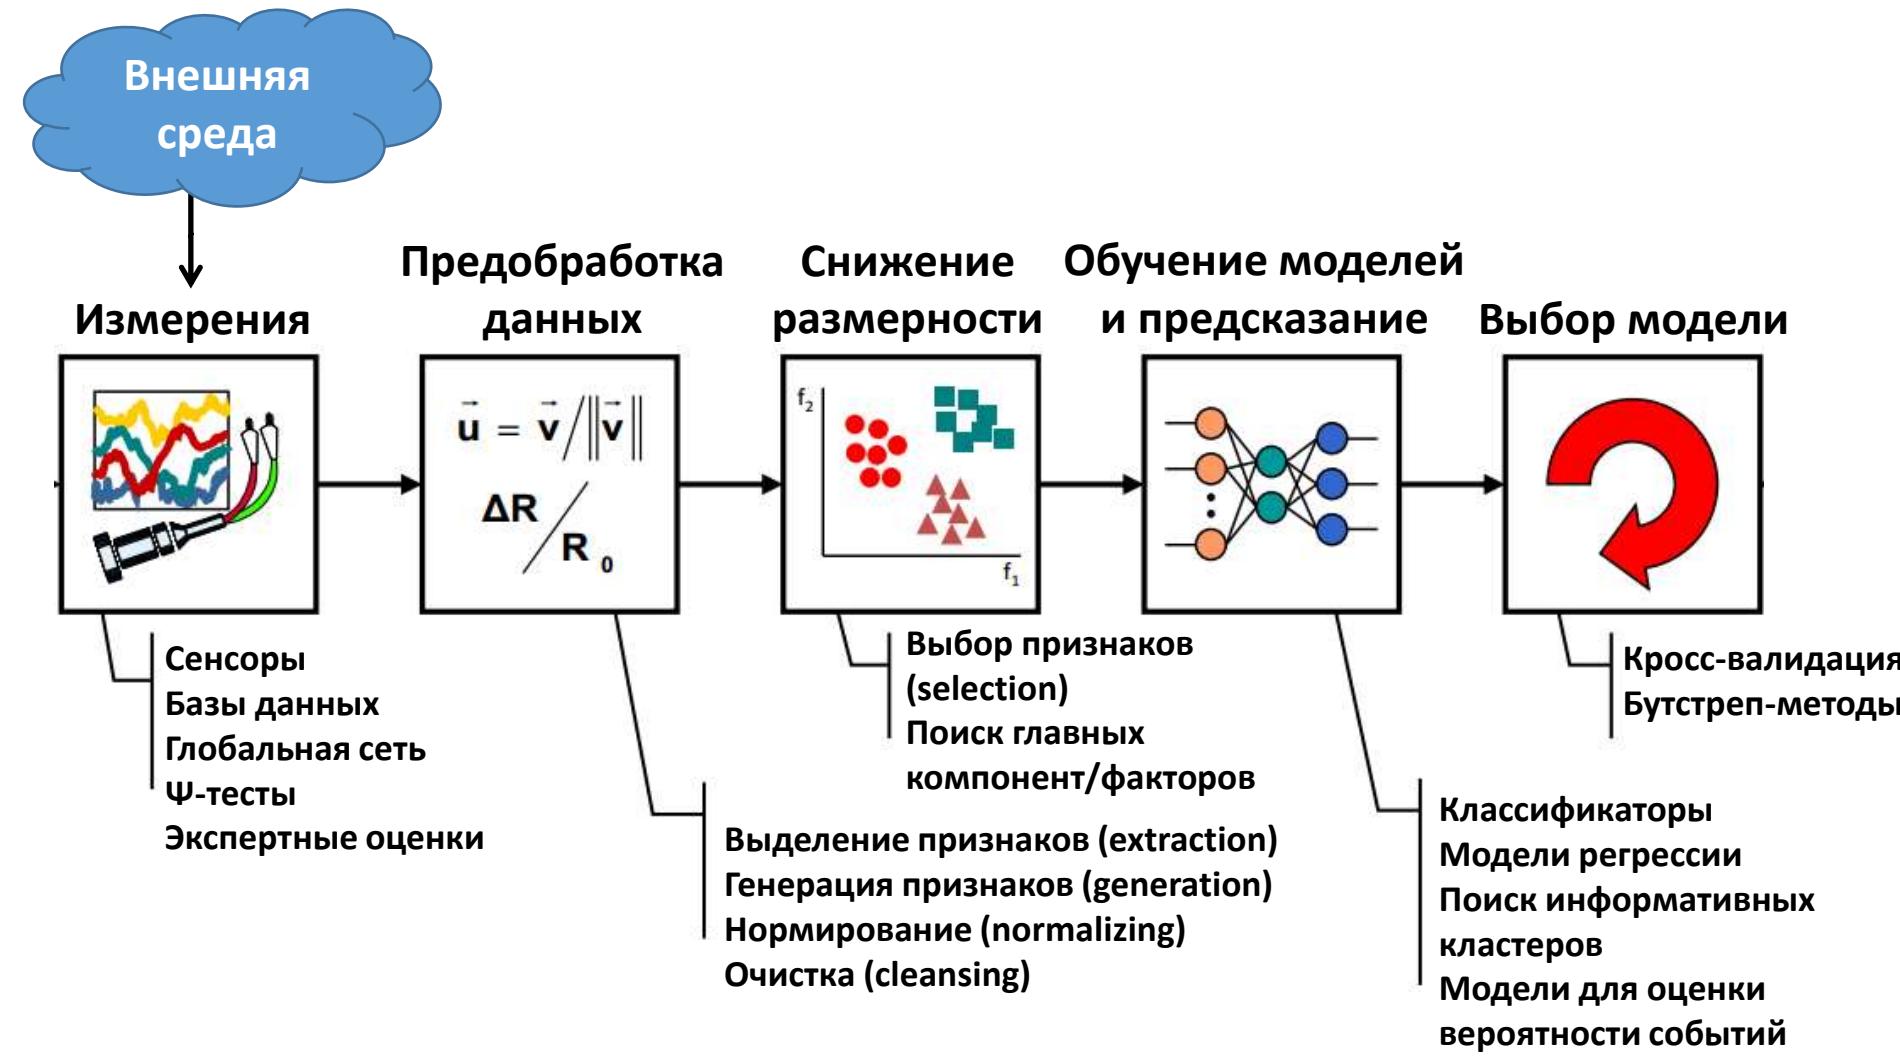
Визуализация и публикация данных для простого использования конечными пользователями

Аналитическая платформа



VISIOLGY

Data Science - как это работает?



ПРОБЛЕМА №1

Плохая формулировка бизнес-цели

НЕ документированная

НЕ измеримая

НЕ пересчитанная в экономический эффект

НЕ согласованная с топ-менеджментом



Понимание бизнеса

Необходимо:

1. Измеримые критерии успешности
2. Оценка экономического эффекта

Пример формулировки бизнес-цели

Бизнес-целью проекта является снижение отходов производства цеха металлообработки П1.2 на 1,5% в течение тестового периода (1 месяц) по отношению к среднему значению за 2016 год.

Показатель отходов производства рассчитывается методом материального баланса по методике РД-1234 с учетом исключения периодов пуска-остановки и ремонта.

Экономический эффект составит 30 млн. руб. в год на протяжении 5 лет за счет снижения затрат на закупку сырья и сокращения персонала, занимающегося уборкой отходов (2 единицы). Эффект утвержден экономическим отделом АО «Хххххх».



ПРОБЛЕМА №2

Недостаточное понимание данных

«Итак, датасет есть, приступим к моделированию!»

Плохой Data Scientist



VISIOLOGY

Понимание данных

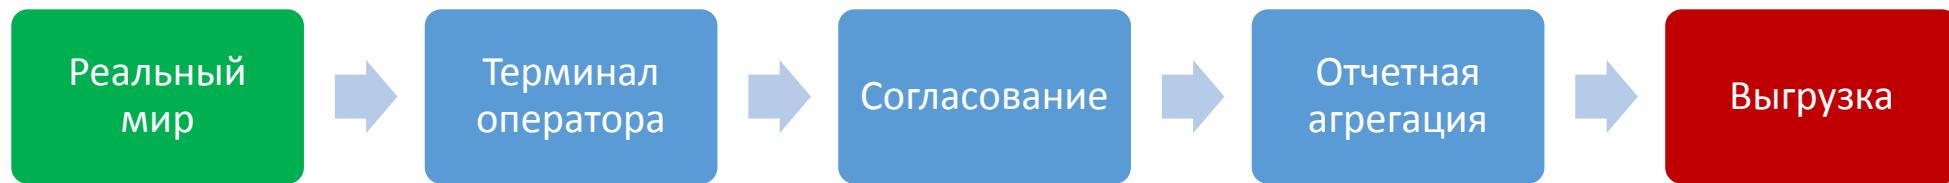
Цепочка преобразований



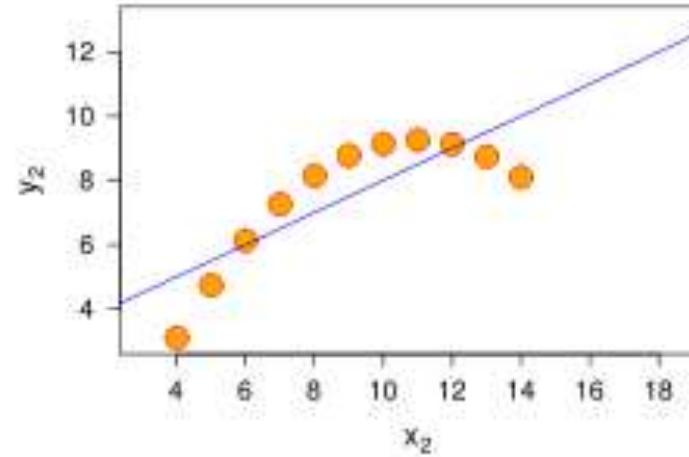
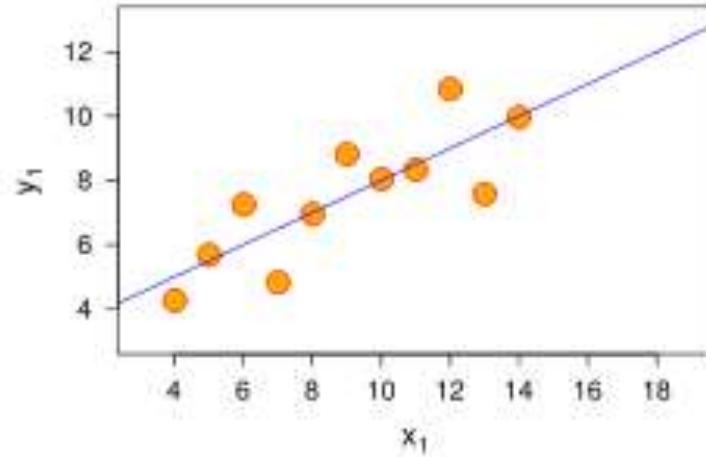
Машинный сбор данных (IoT, IIoT транзакционные системы)



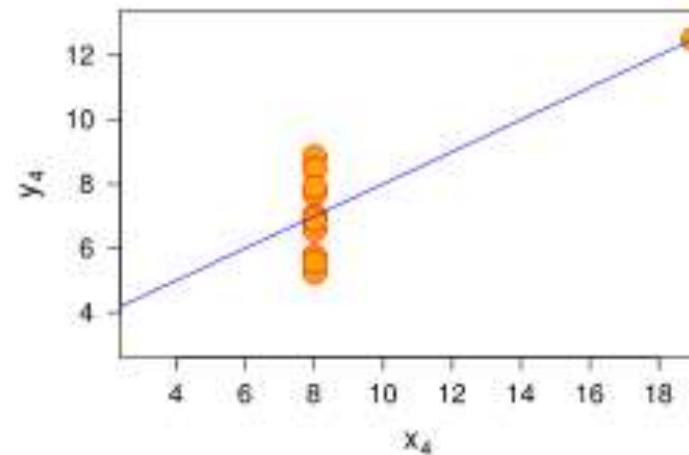
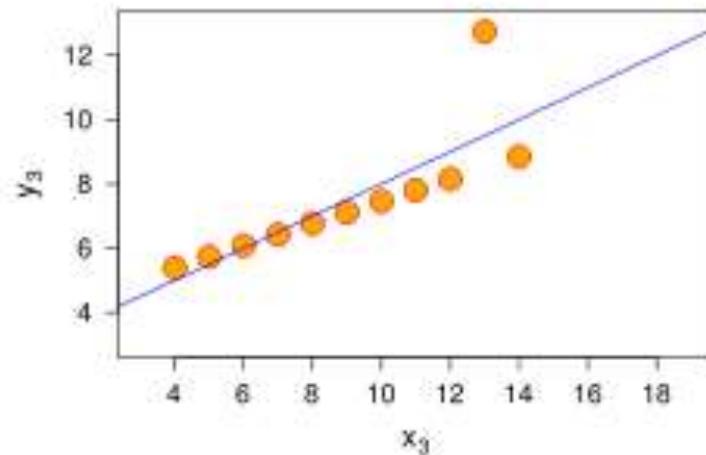
Ручной ввод данных (отчетные данные, системы с оператором)



Почему понимание данных критически важно?



Характеристика	Значение
Среднее значение переменной x	9,0
Дисперсия переменной x	10,0
Среднее значение переменной y	7,5
Дисперсия переменной y	3,75
Корреляция между переменными x и y	0,816
Прямая линейной регрессии	$y = 3 + 0,5x$



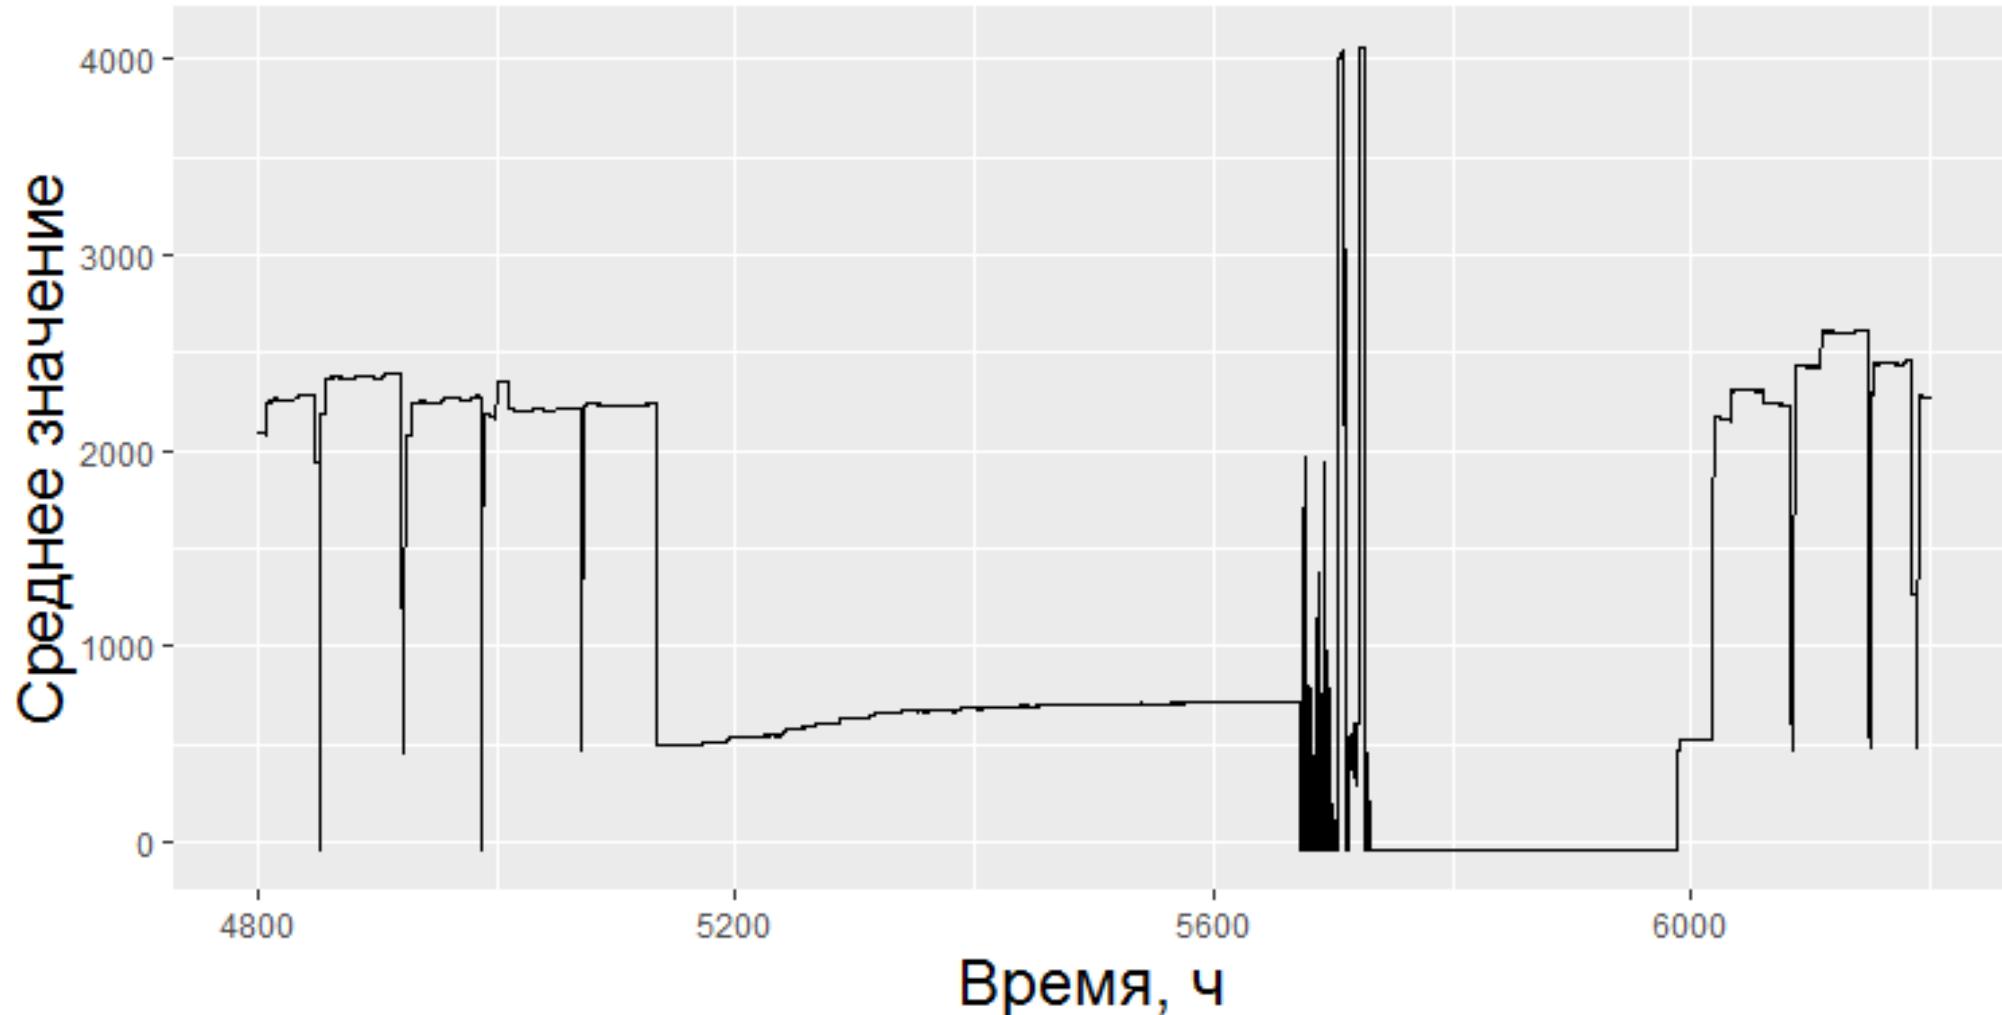
Машинный сбор данных

Реальный
мир



Датчик

Нетипичные изменения частотного состава сигнала и выгрузка некорректных значений, соответствующих периоду останова процесса



VISIOLOGY

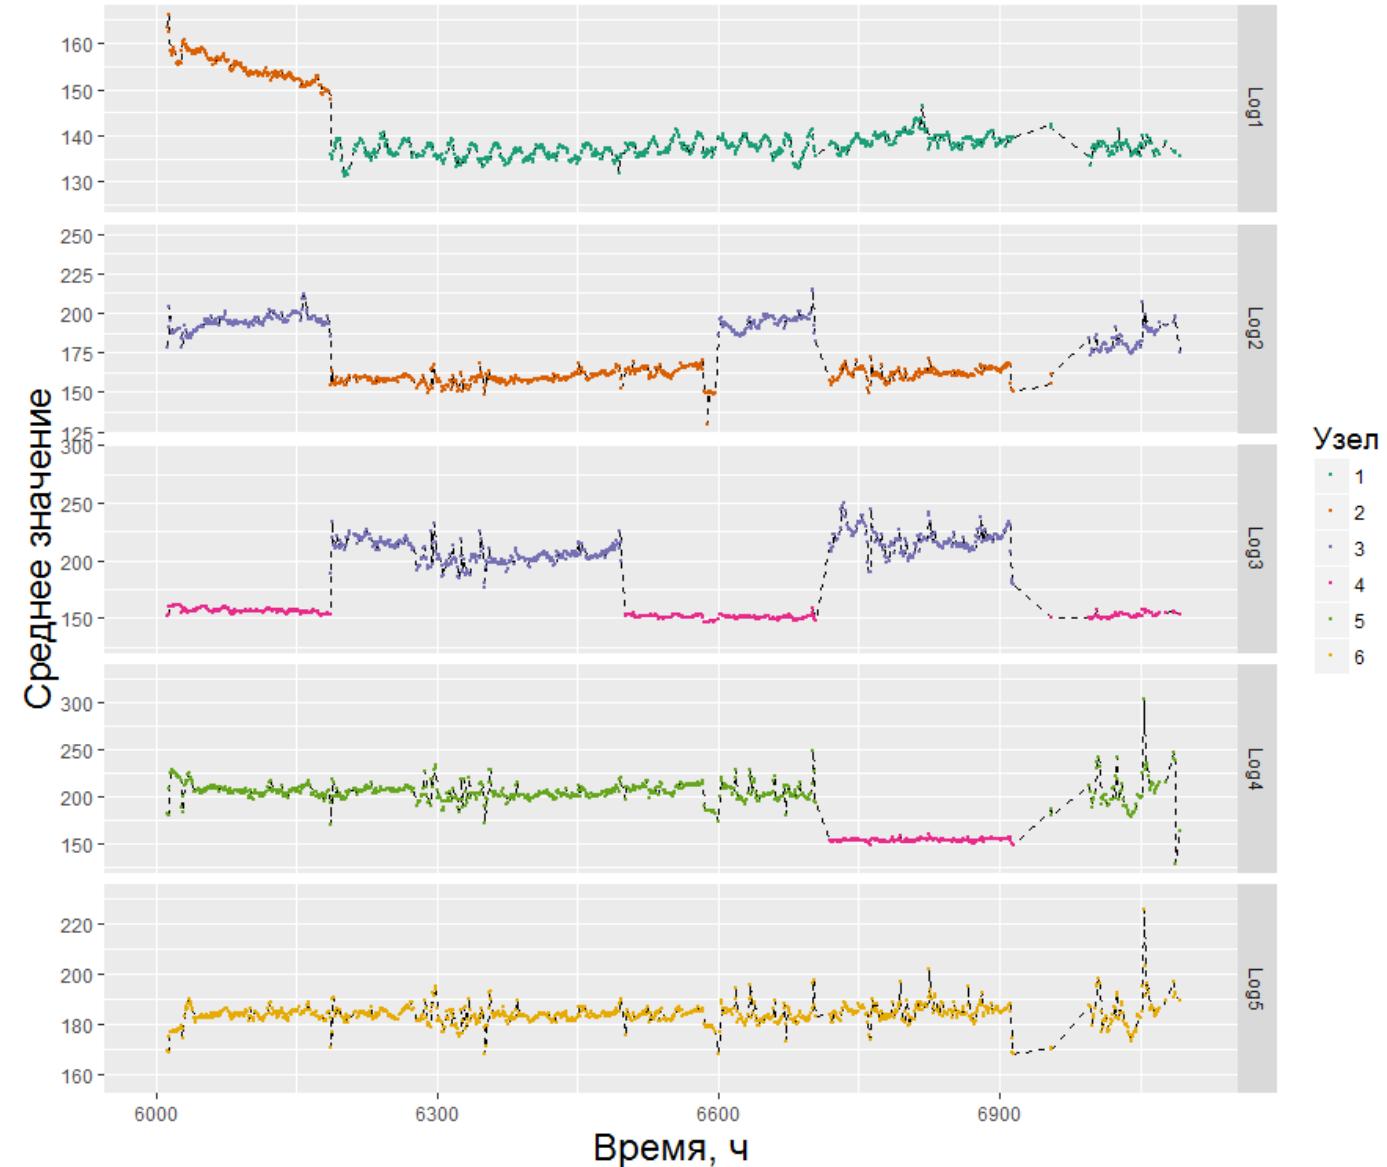
Машинный сбор данных

Реальный
мир



Датчик

Гетерогенность свойств типовых узлов и случаи реконфигурации системы, порождающие необходимость нормировки сигналов



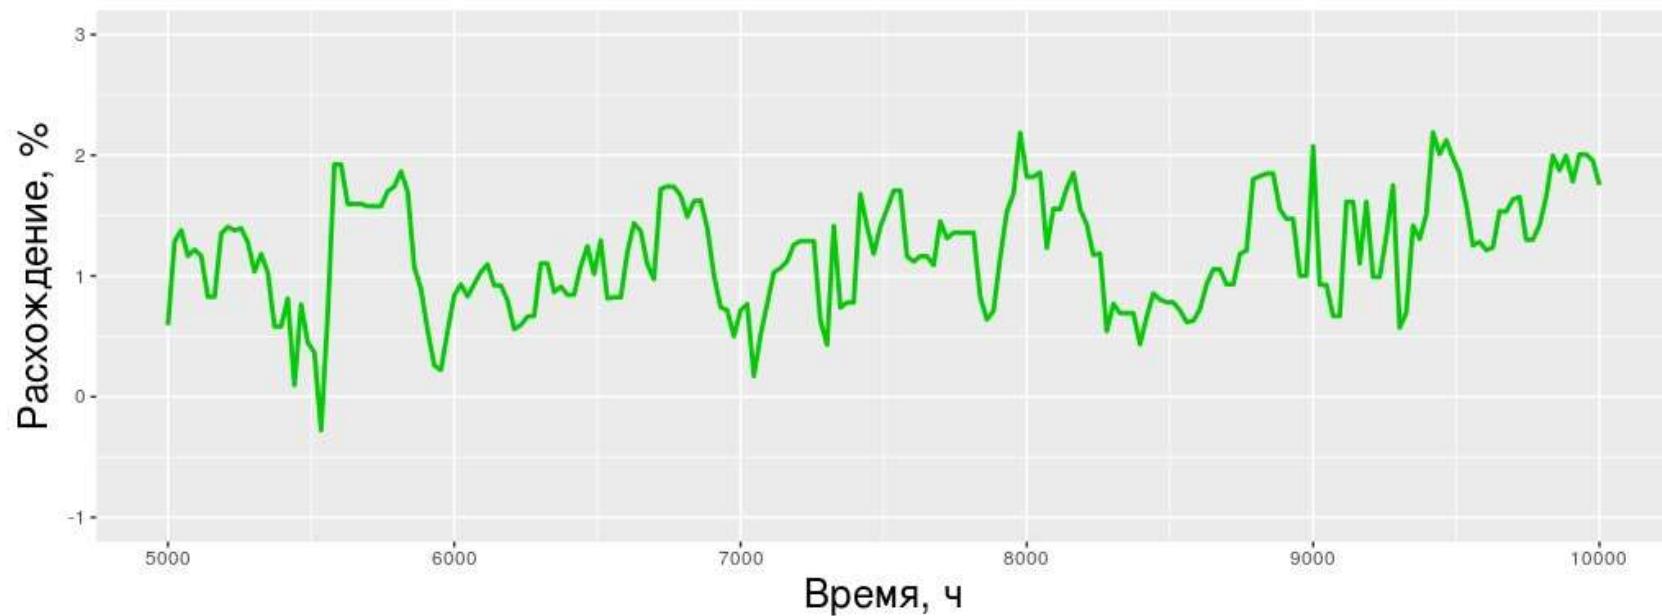
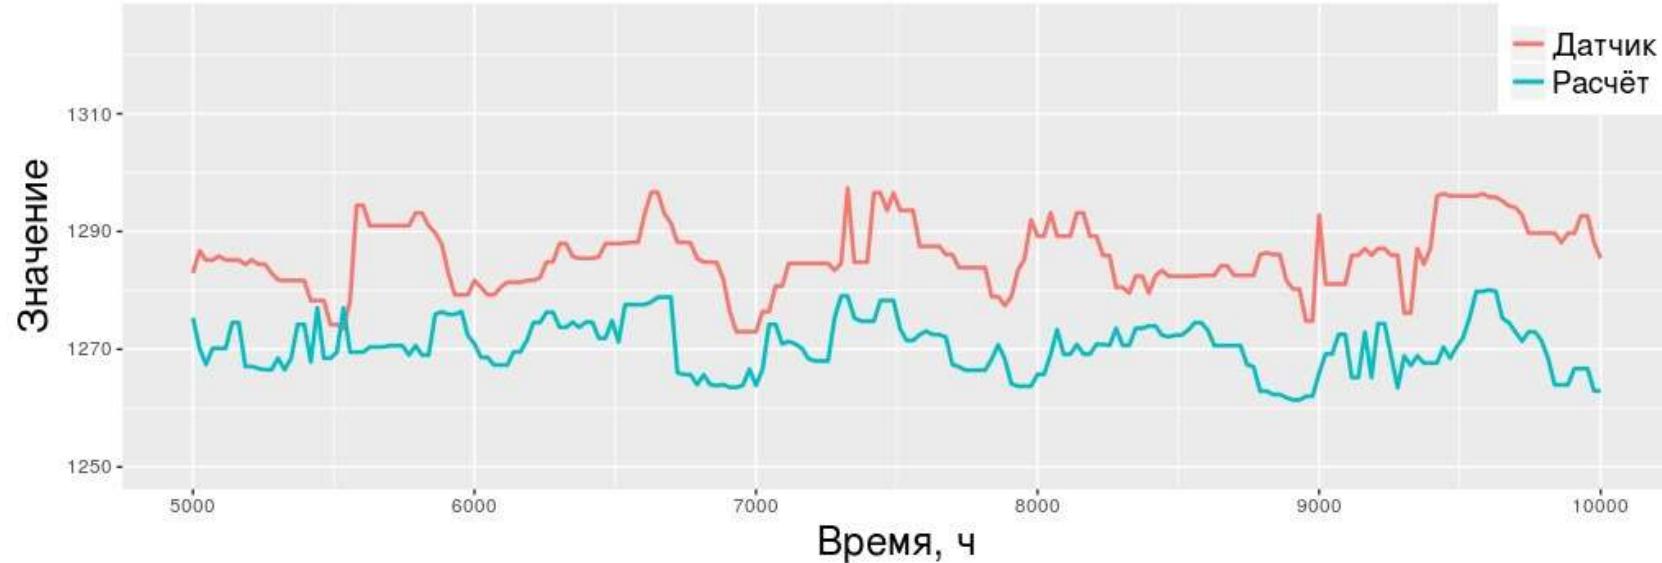
VISIOLOGY

Машинный сбор данных

Датчик

АСУТП

Расхождение расчётов по теоретическим формулам с показаниями виртуальных датчиков в АСУТП



VISIOLOGY

ОШИБКА #3 НЕДОСТАТОЧНАЯ РАБОТА АНАЛИТИКОВ НА ПРОИЗВОДСТВЕ



Обследование за 3-4
консультации, пару
поездок и в остальное
время работа с
датасетами и
документацией



РЕАЛЬНОСТЬ



Регулярные 1-2 недели на производстве в начале проекта и контакт с технологическими экспертами залог:

- ✓ качественного обследования
- ✓ Качественной разметки датасета и отбора обучающих выборок
- ✓ понимания процесса
- ✓ правильной постановки задачи и цели
- ✓ Корректировки и проверки модели в процессе R&D



ОШИБКА #4 ПОСТРОЕНИЕ МОДЕЛЕЙ ТОЛЬКО МЕТОДОМ ЧЕРНОГО ЯЩИКА



РЕАЛЬНОСТЬ

Очищенные данные



Пригодные для
моделирования
данные

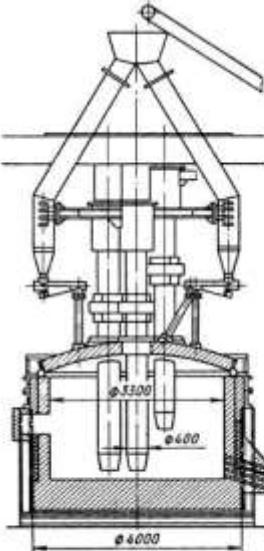


Рис. 106. Схема опытной руднотермической печи фирмы "Крупп"

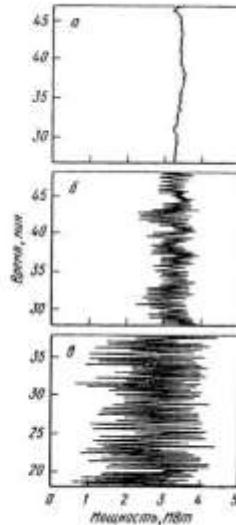
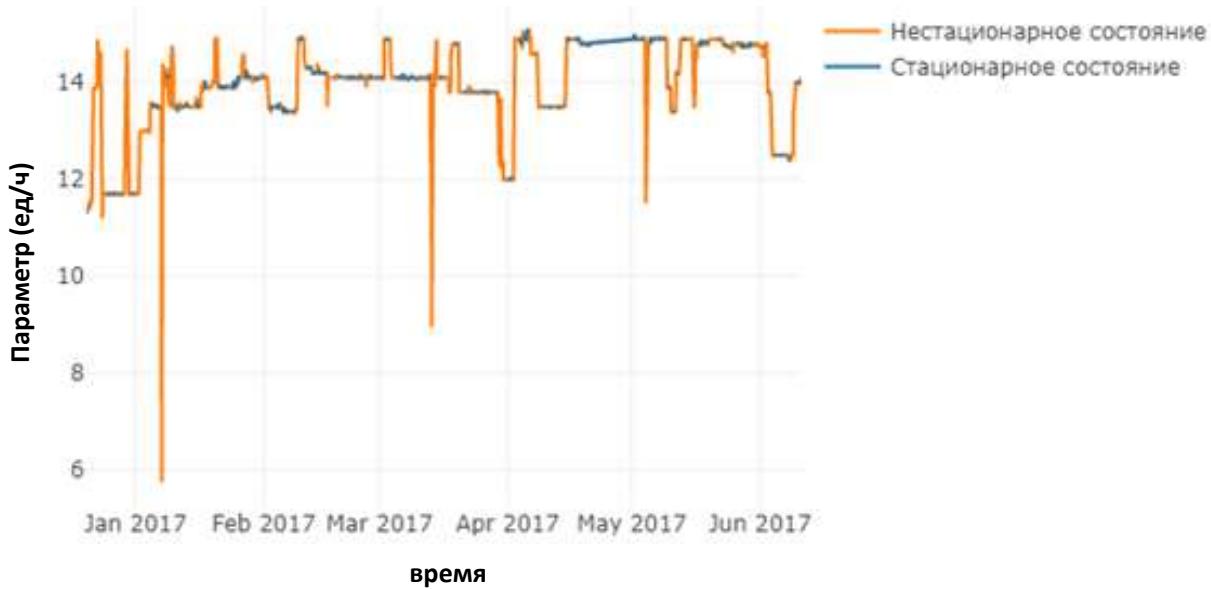


Рис. 107. Потребляемая мощность на
опытных плавках при различном сост-
аве шлака



- ✓ После очистки и преобразования остается слишком мало данных для моделей «черного ящика»
- ✓ Сложные зависимости между параметрами, которые модели не улавливают – часть производства «черный ящик»
- ✓ Возможно какая-то часть важных данных и измерений отсутствует или не измеряется вовсе
- ✓ Особенности оборудования, оснастки и расходного материала, расчеты – секретное «ноу-хау» производителя, которые он тщательно охраняет даже под NDA
- ✓ Необходимо понимать производство и расчеты для сокращения размерности моделей



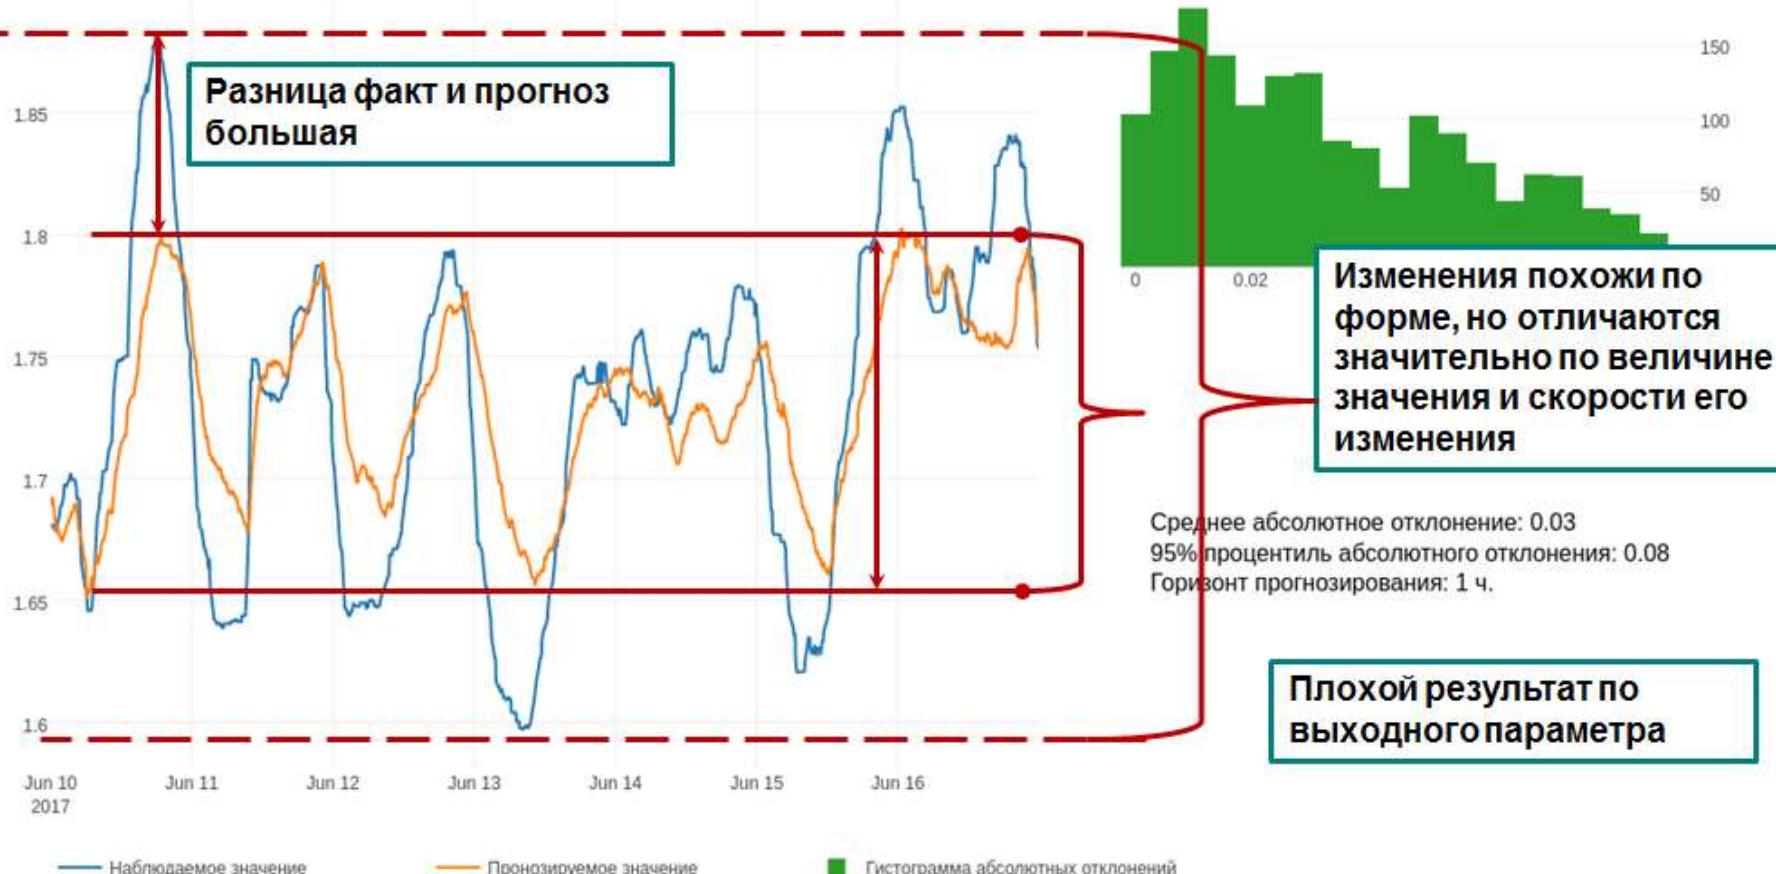
ОШИБКА #5 ДОВЕРИЕ СЛЕПЫМ ТЕСТАМ ПРИ ОЦЕНКЕ КАЧЕСТВА МОДЕЛИ



Решая задачи с данными
реального времени,
нельзя полагаться на успешные
результаты слепого теста



РЕАЛЬНОСТЬ



Модель должна проходить несколько экспериментальных проверок в процессе разработки

- ✓ На эксперименте ошибки становятся в 2 раза заметнее и их величина и значимость растет
- ✓ Данные меняются в режиме реального времени, имеют внешние возмущения (воздействия) затрудняющие получение чистого результата
- ✓ В непрерывных процессах сложно заставить оператора ТП выйти из зоны комфорта привычных действий



ОШИБКА #6

НЕДОСТАТОЧНОЕ ВОВЛЕЧЕНИЕ ИСПОЛНИТЕЛЕЙ И ПОЛЬЗОВАТЕЛЕЙ



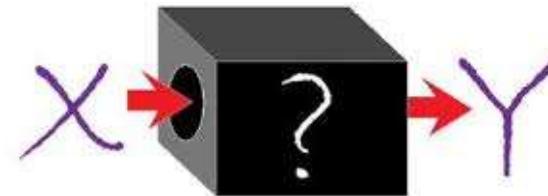
4 причины почему важно плотно работать с будущими пользователями модели:

1. Получить нужную информацию
2. Получить нужную ценность и функциональность (см. ошибку #1)
3. Повысить доверие к результату
4. Вовлечь пользователей и обеспечить дальнейшее использования модели пользователями в рабочем процессе



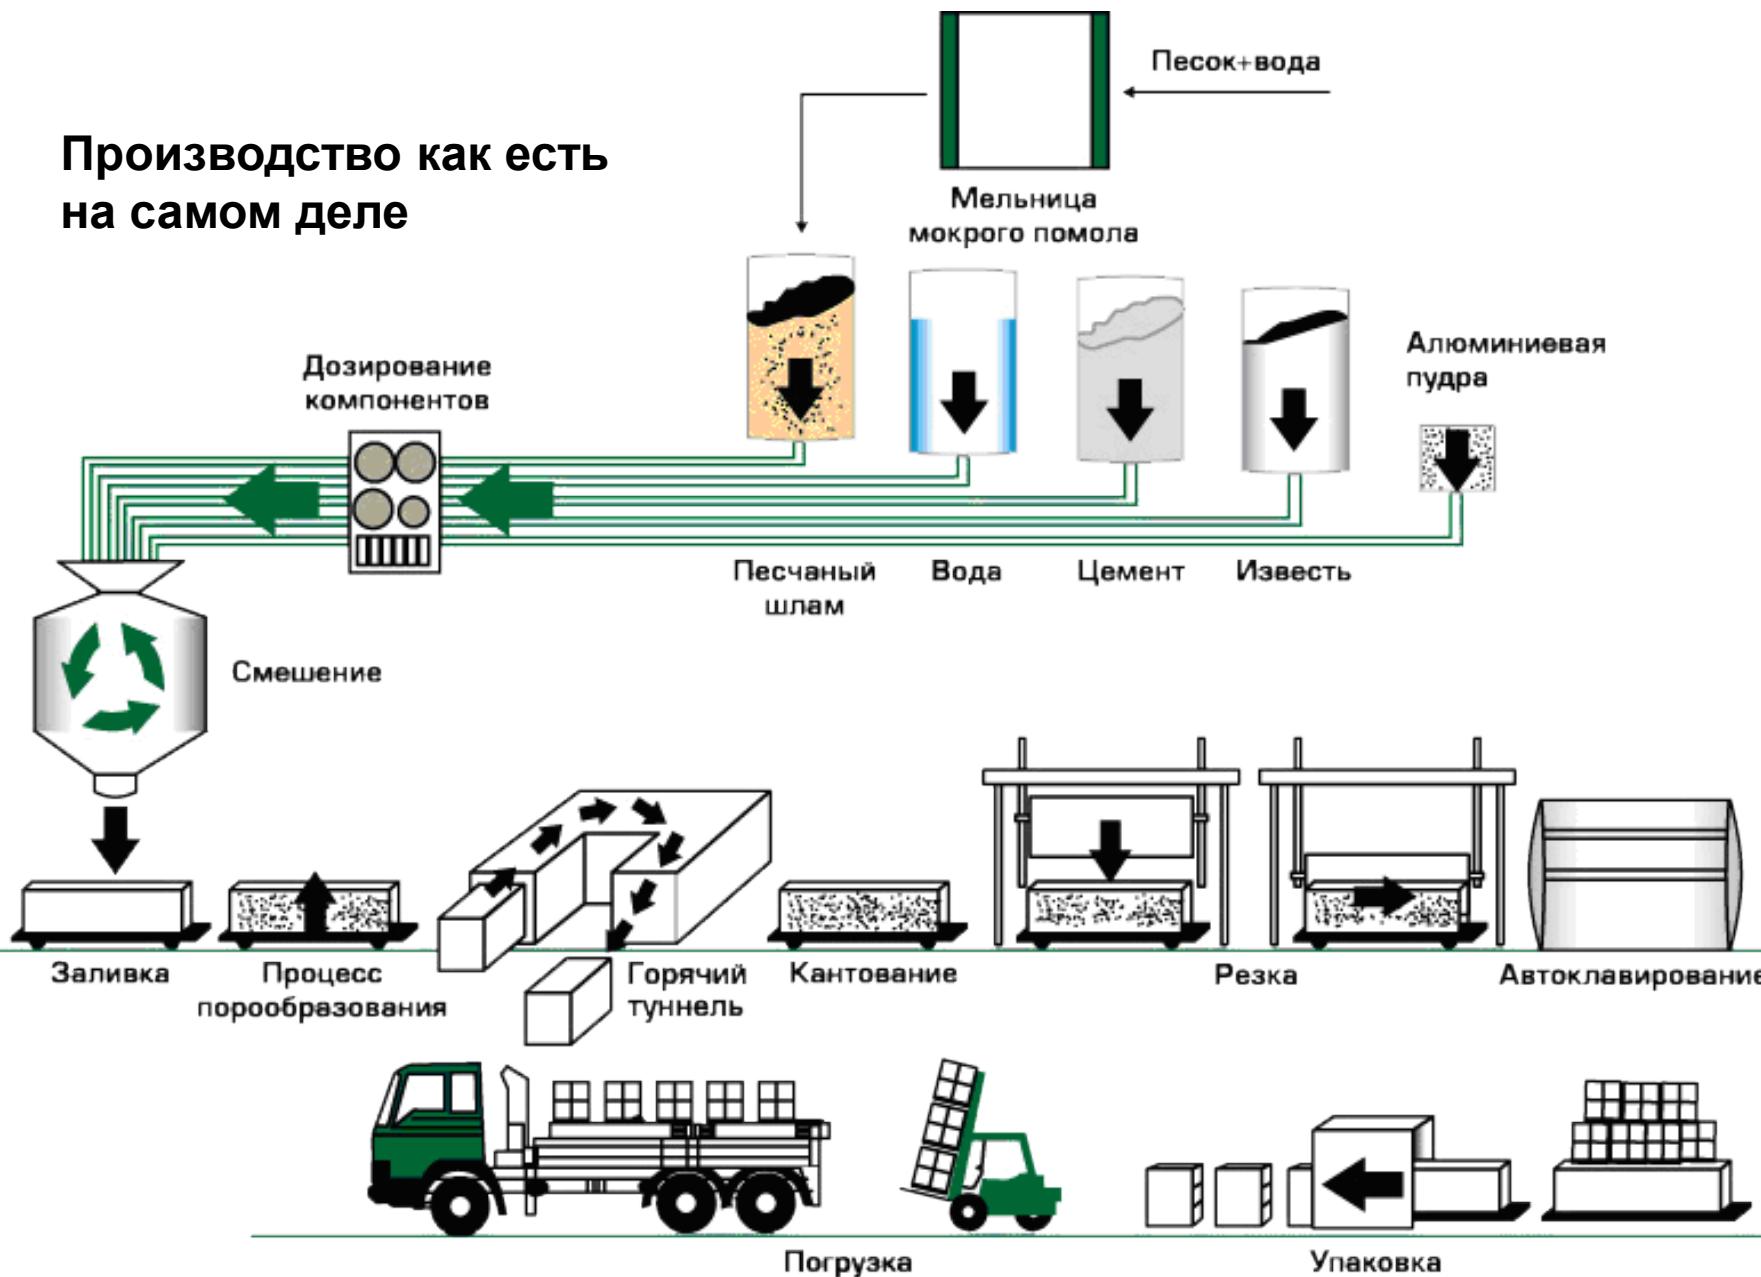
ОШИБКА #7 НЕДОСТАТОЧНАЯ ОЦЕНКА ИЗМЕНЧИВОСТИ ПРОЦЕССА

Производство как нам кажется в начале



РЕАЛЬНОСТЬ

Производство как есть
на самом деле



4 причины постоянной проверки модели на адекватность:

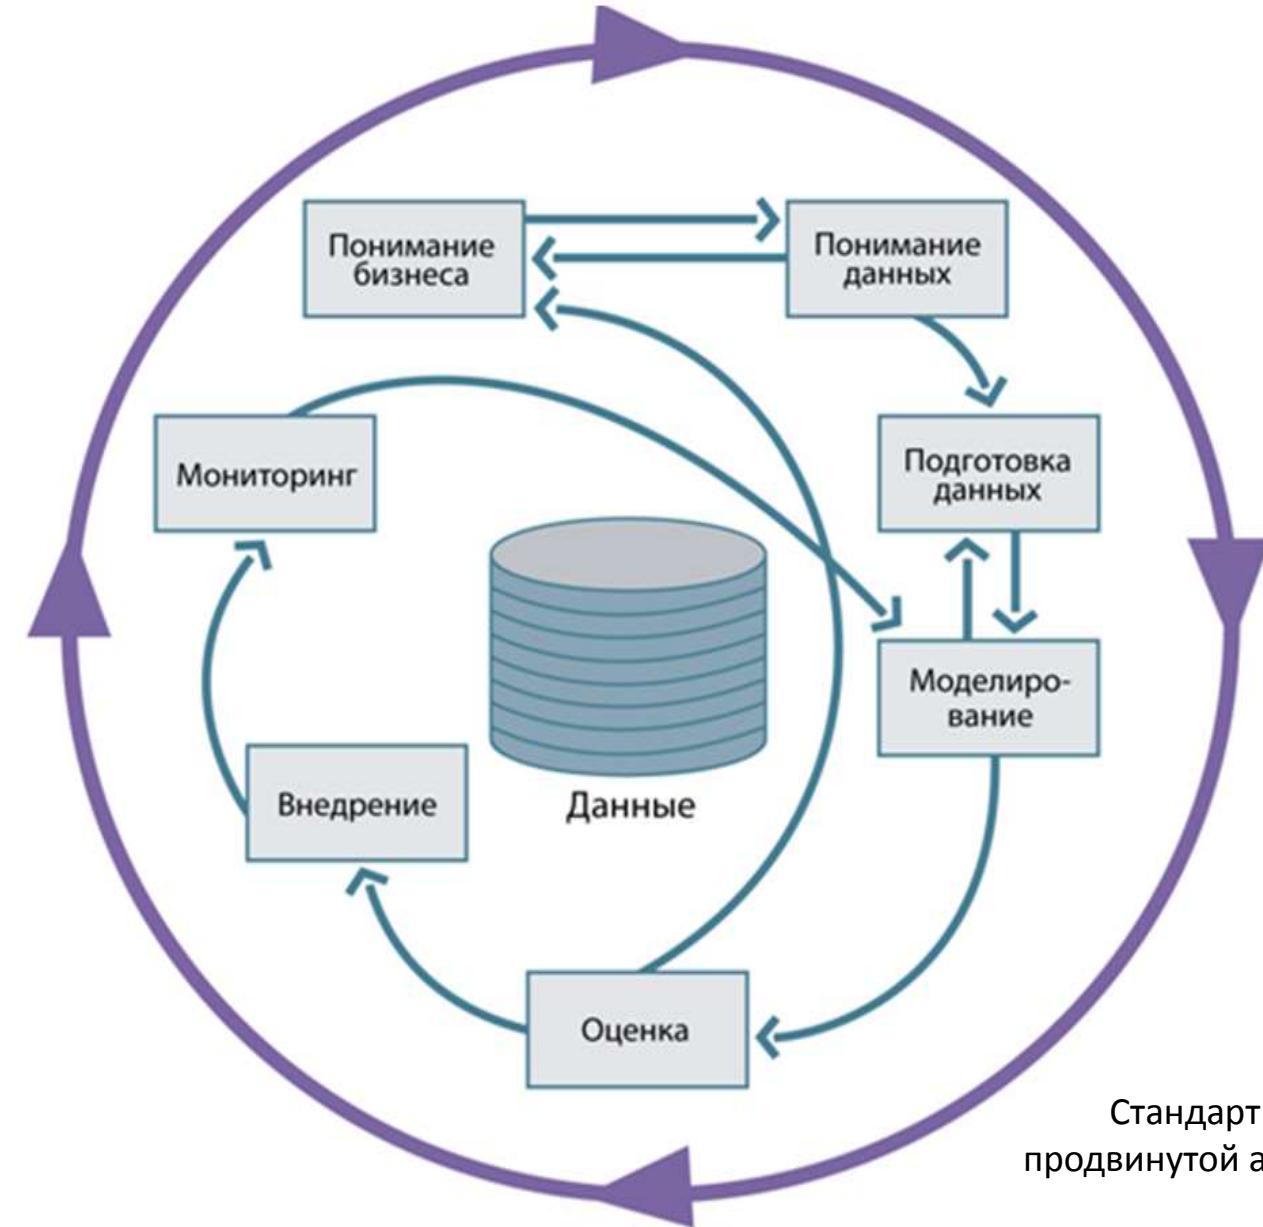
1. постоянные внутренние и внешние возмущения на процесс могут менять его параметры
2. необходимо четко понимать границы применимости модели (допущения, граничные условия)
3. сложная мат. модель может выдавать неправильные результаты
4. высокая стоимость ошибки



Data Science - как это работает?

Data Science – это набор методик и практик для решения задач продвинутого анализа данных, в том числе:

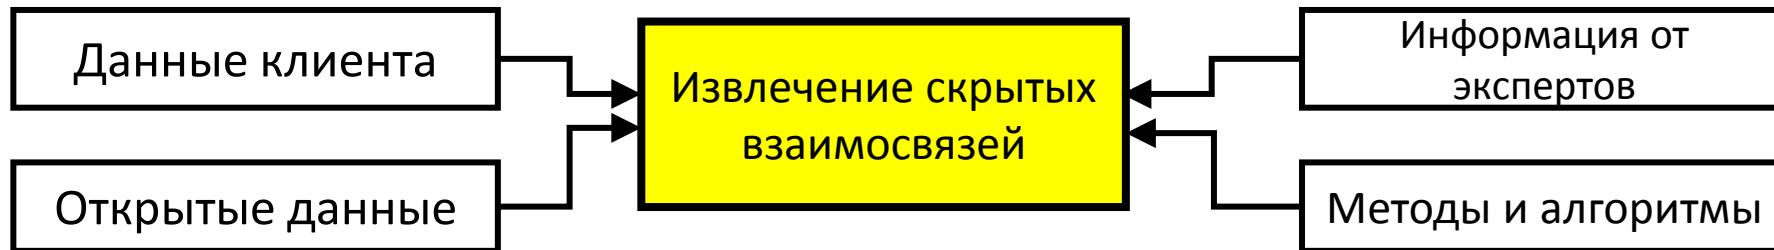
1. Подготовка (очистка)
2. Моделирование с применением методов **машинного обучения**
3. Оценка и верификация
4. Визуализация



Стандарт процесса
продвинутой аналитики
CRISP-DM

Типовой план проекта

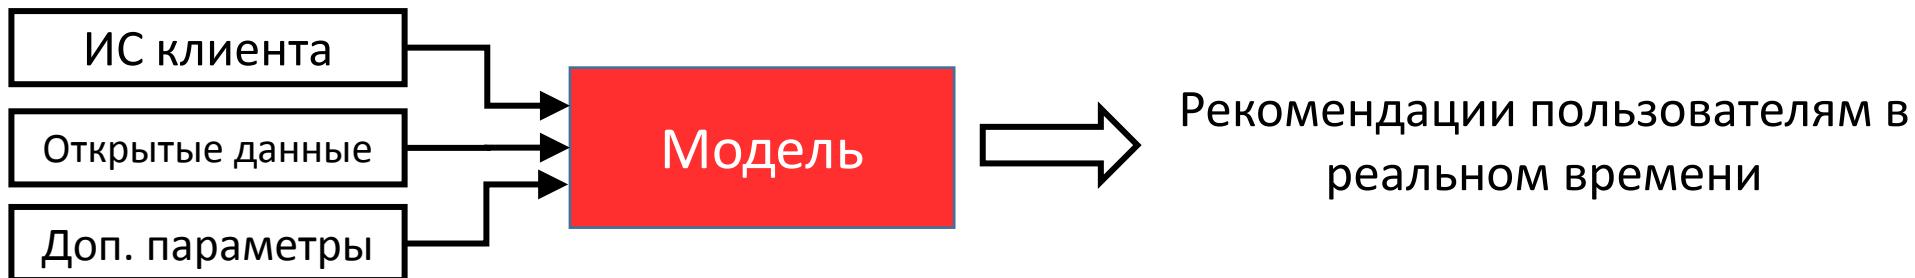
1. Разведочный анализ и предварительное моделирование (**~3 месяца**)

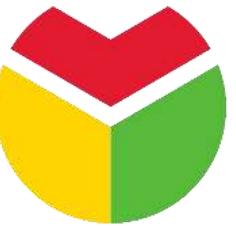


2. Разработка математических моделей и интеграция с источниками данных (**1-4 месяца**)

3. Опытная эксплуатация и корректировка модели (**2-4 месяца**)

4. Внедрение в промышленную эксплуатацию, поддержка.





VISIOLOGY

www.visiology.su



VISIOLOGY