



АНАЛИЗ ЭФФЕКТИВНОСТИ СОВРЕМЕННЫХ ИНФОРМАЦИОННЫХ МЕТОДОВ ВЫЯВЛЕНИЯ НЕТЕХНИЧЕСКИХ ПОТЕРЬ ЭЛЕКТРОЭНЕРГИИ

В.О. Самойленко, Н.Д. Мухлынин, А.М. Верховзин, В.А. Тащилин, А.В. Паздерин

Докладчик: В.О. Самойленко

НТС ЕЭС, 16.11.2023



НЕТЕХНИЧЕСКИЕ ПОТЕРИ ЭЛЕКТРОЭНЕРГИИ: АКТУАЛЬНОСТЬ, НОВИЗНА И ЗНАЧИМОСТЬ

1. Уровень нетехнических потерь электроэнергии (НПЭЭ):

- В мире от 0,15 % до 60 %, в т.ч. в развитых странах 4,0-5,5 % и в развивающихся 11-19 %;
- В РФ от 0,26 % до 25 % в зависимости от региона.

2. Первые публикации о борьбе с НПЭЭ в мире датированы 1899 г. (страна – Российская Империя). За 120+ лет многие исследователи и научные школы занимались проблемой выявления НПЭЭ.

3. Методы выявления НПЭЭ делятся на две группы:

- Схемно-технические – на основе теоретических основ электротехники (балансы и/или поэлементный расчет потерь);
- Информационные – на основе выявления аномалий профиля потребления ЭЭ или неэлектрических параметров.

4. Базой для развития информационных методов является Постановление Правительства РФ от 19 июня 2020 г. N 890 "О порядке предоставления доступа к минимальному набору функций интеллектуальных систем учета электрической энергии (мощности)", предписывая сбор 30-минутных измерений ЭЭ и других электрических параметров.

100

млрд. долл. ежегодно

Оценка Всемирным банком
прямого и косвенного
ущерба от НПЭЭ в мире

60

млрд. рублей ежегодно

Прямой ущерб от НПЭЭ в РФ
по официальным отчетам
электросетевых организаций



НЕГАТИВНОЕ ВЛИЯНИЕ НПЭЭ НА АКТИВНЫЕ РАСПРЕДСИСТЕМЫ. БОРЬБА С НПЭЭ

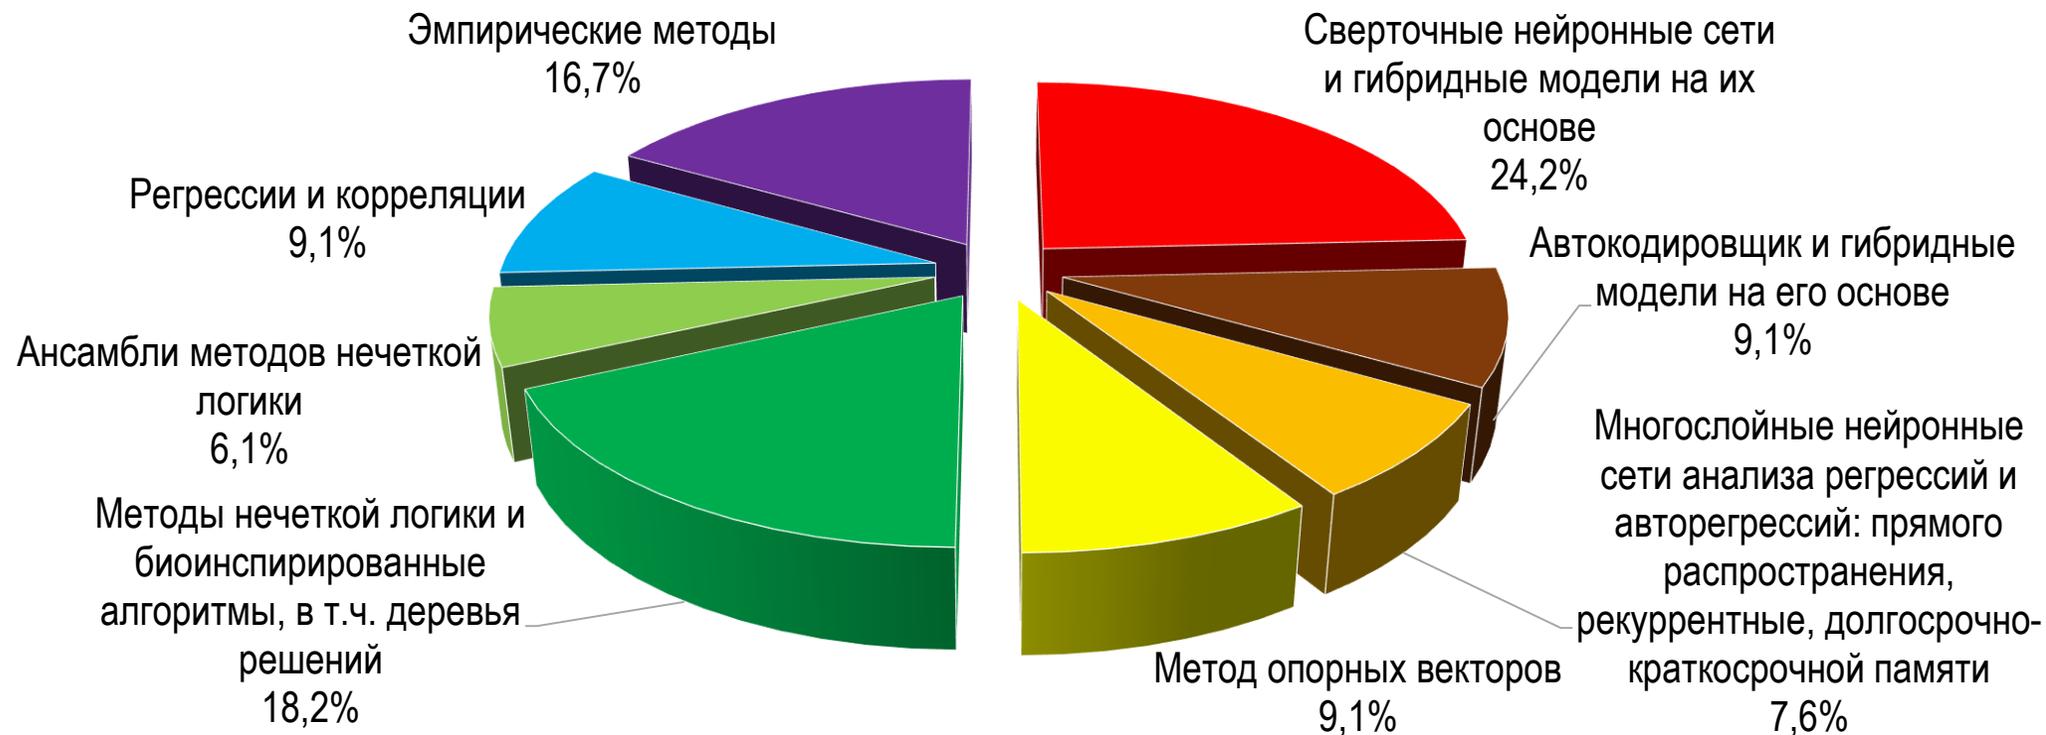
На примере научных статей Генеральной сессии CIGRE 2022 г.

№ статьи	Страна	Объект или проект	Проблема
10281, 10331	Ю. Корея	Накопитель энергии на основе литиевой АКБ	Ввиду потребления ЭЭ большего, чем принималось по показаниям средств учета ЭЭ, накопитель энергии не вышел на расчетный цикл суточного регулирования ночных провалов и срезки дневных пиков
10175	Бразилия	Накопитель энергии на основе литиевой АКБ	Ввиду потребления ЭЭ большего, чем принималось по показаниям средств учета ЭЭ, не выполнены требования по продолжительности резервирования сети накопителем энергии (ТЗ 12 ч; расчет 12:30 ч; факт 11:15 ч)
11131	ЮАР	Распределительная сеть 132 кВ и ниже	Проект электрификации территории не окупился ввиду больших НПЭЭ и дебиторской задолженности населения

1. В распредел. сетях РФ функционируют программные комплексы для выявления НПЭЭ информационными методами:
 - ПК «Радар» на основе VK Predict, изначально приложение для таргетирования рекламы в социальных сетях;
 - Облачное решение EnergyTool от МТС, изначально система геометрики для решения вопросов развития сотовой сети.
2. В мире в эксплуатации находится 12 программных комплексов для выявления НПЭЭ информационными методами.



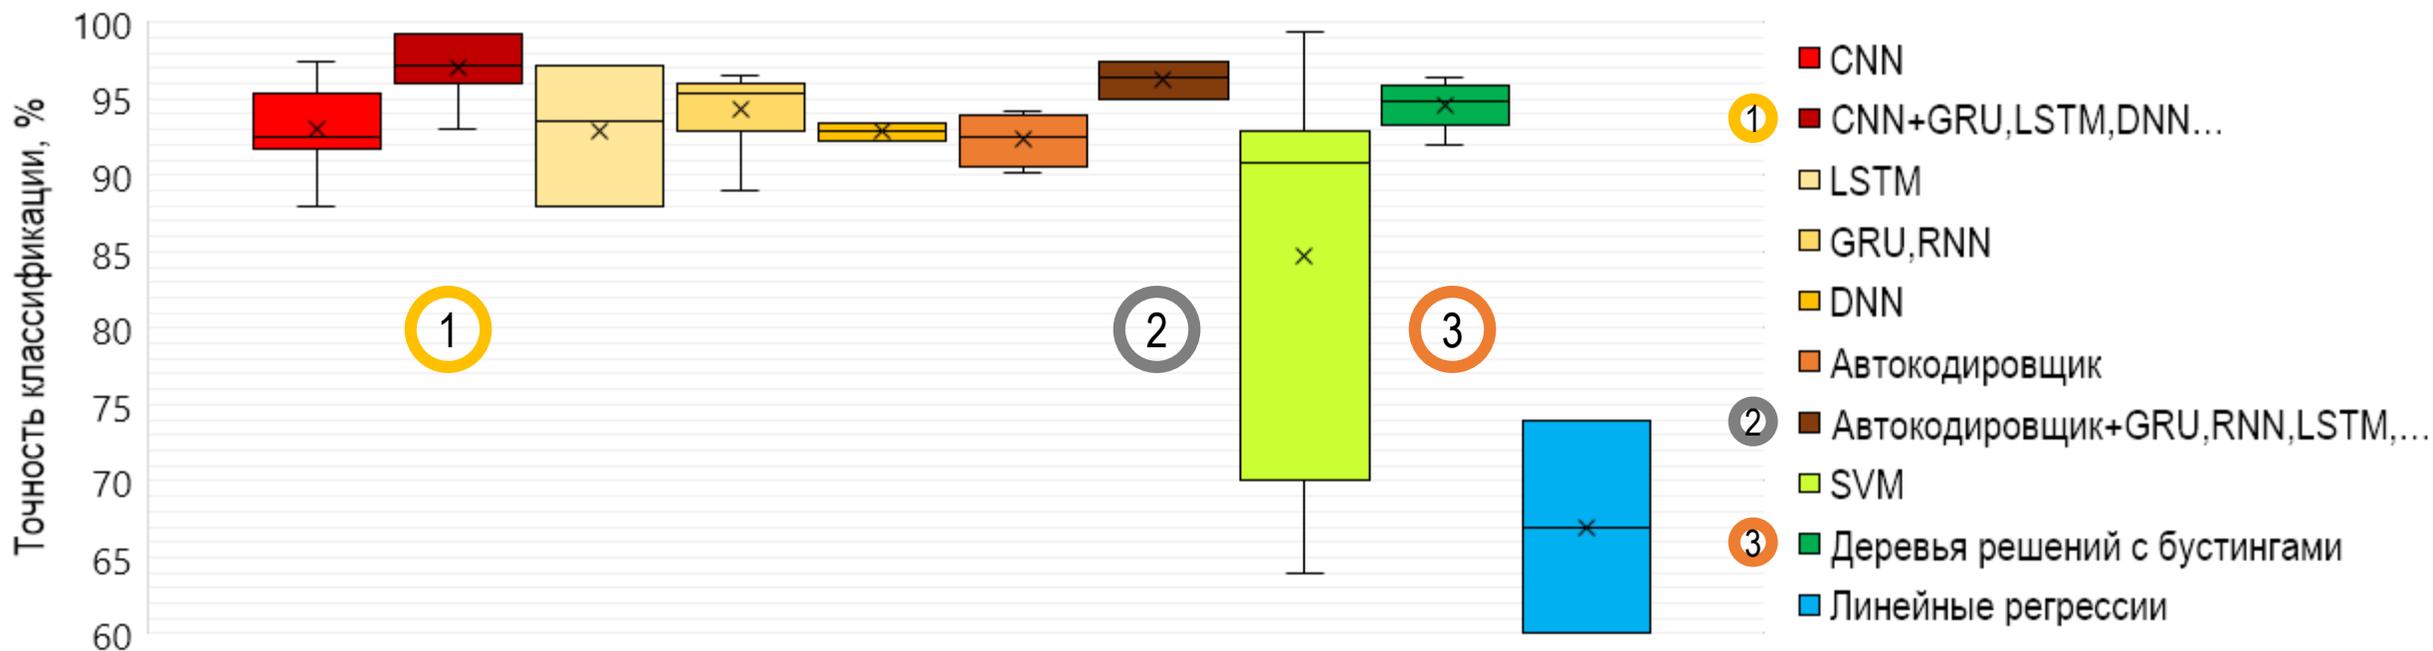
ПОПУЛЯРНОСТЬ МОДЕЛЕЙ И МЕТОДОВ ВЫЯВЛЕНИЯ НПЭЭ НА ОСНОВЕ 130+ ИСТОЧНИКОВ



- Нейронные сети различных видов используются в 40,9 % – основная группа методов после 2020 г.;
- Наиболее используемая разновидность нейронных сетей – сверточные нейронные сети: 24,2 % от общего количества публикаций;
- В меньшей степени используются Автокодировщик и другие нейронные сети прямого распространения;
- В ранних публикациях до 2020 г. широко использовались метод опорных векторов и деревья решений с различными бустингами.



СОПОСТАВЛЕНИЕ ЧУВСТВИТЕЛЬНОСТИ ОСНОВНЫХ МОДЕЛЕЙ И МЕТОДОВ



- Традиционный анализ регрессий и корреляций ввиду чувствительности 74 % и менее непригоден для выявления НПЭЭ;
- Метод опорных векторов в зависимости от алгоритма предобработки дает большой разброс чувствительности, среднее на уровне 85 %;
- Нейронные сети одного вида: сверточные, автокодировщики, долгосрочно-краткосрочной памяти, рекуррентные достигают ч-ти 92-94 %;
- Деревья решений с бустингами обучения являются самым чувствительным из условно-наглядных для человека методов, достигая ч-ти 95 %;
- Гибридные модели с элементами памяти (рекурсии) на основе автокодировщика и сверточной нейронной сети дают ч-ть 96 % и 97 % (до 99%), соответственно. Но при этом автокодировщик проще в реализации и обучении.



ИСПОЛЬЗУЕМАЯ В ПУБЛИКАЦИЯХ МЕТРИКА ЭФФЕКТИВНОСТИ ВЫЯВЛЕНИЯ НПЭЭ

Обозначение		Формула	Описание и смысл показателя	Примечание
Rec, Sen, TPR	Recall, Sensitivity, True positive rate Чувствительность, частота истинно-положительных значений	$TP / (TP + FN)$	Способность алгоритма выявлять НПЭЭ в те часы, когда они действительно были	Используются вместе для полного описания особенностей алгоритма и сопоставления их между собой
FPR	False positive rate Частота ложно-положительных значений	$FP / (FP + TN)$	Ошибочная реакция алгоритма на аномалии в те часы, когда НПЭЭ не было	
Spe, TNR	Specificity, True negative rate Специфичность, частота истинно-отрицательных значений	$TN / (TN + FP)$ или $1 - FPR$	Способность алгоритма не реагировать на аномалии в те часы, когда НПЭЭ не было	
Pre	Precision Разборчивость, точность	$TP / (TP + FP)$	Способность алгоритма отличать НПЭЭ от аномалий при сложном профиле нагрузки	
Асс	Ассурасу Достоверность, точность	$(TP + TN) / (TP + TN + FP + FN)$	Доля успешно определенных интервалов с НПЭЭ и успешно отсеянных интервалов без НПЭЭ в профиле	! Для сбалансированных данных
ROC-кривая	Receiver operating characteristic Рабочая характеристика приёмника	-	Эффективность классификатора в координатах {«доля ложно-положительных»; «доля истинно-положительных»}	Графическая качественная характеристика
AUC	Area under curve Область под ROC-кривой ошибки	$S(ROC) / S(FPR \cdot TPR)$	Доля площади под ROC-кривой от общей площади FPR-TPR квадрата	Количественная характеристика

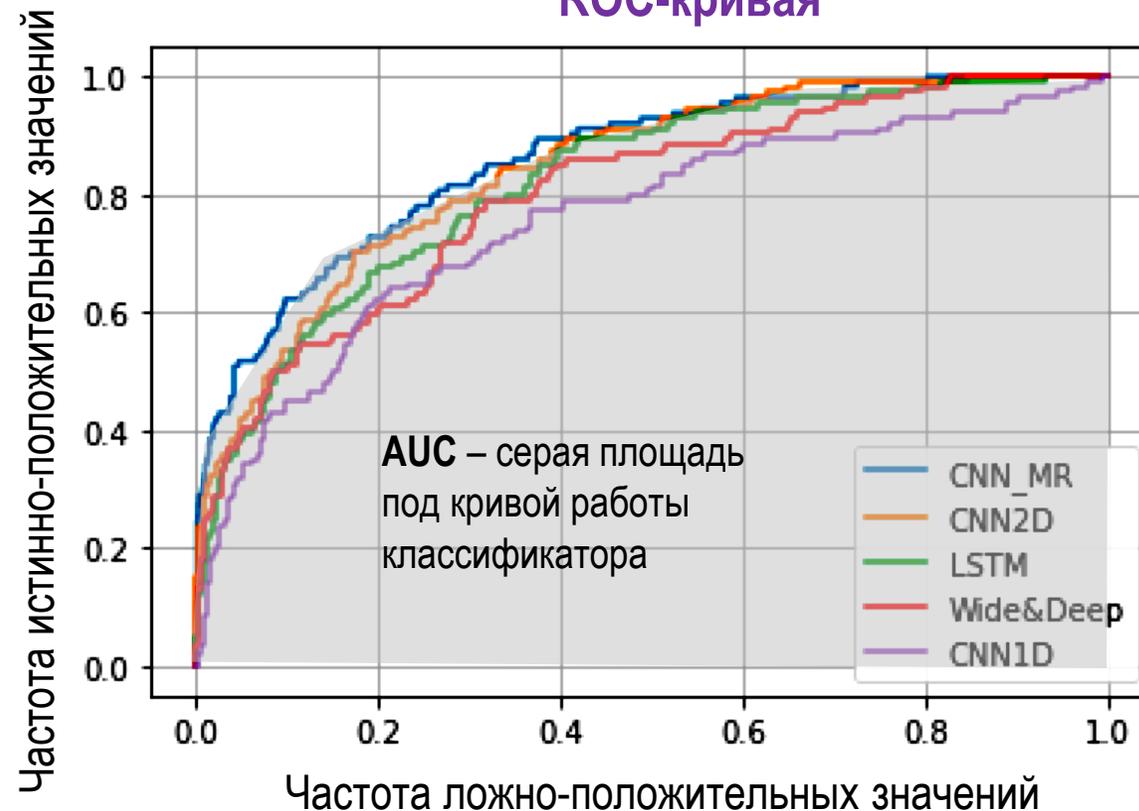


ГРАФИЧЕСКАЯ ИНТЕРПРЕТАЦИЯ МЕТРИКИ ЭФФЕКТИВНОСТИ ВЫЯВЛЕНИЯ НПЭЭ

Матрица классификации

Измерения	Распознаны как измерения, НЕ содержащие НПЭЭ	Распознаны как измерения, содержащие НПЭЭ
Измерения, НЕ содержащие НПЭЭ	Истинно-отрицательные (True Negative, TN)	Ложно-положительные (False Positive, FP)
Измерения, содержащие НПЭЭ	Ложно-отрицательные (False Negative, FN)	Истинно-положительные (True Positive, TP)

ROC-кривая



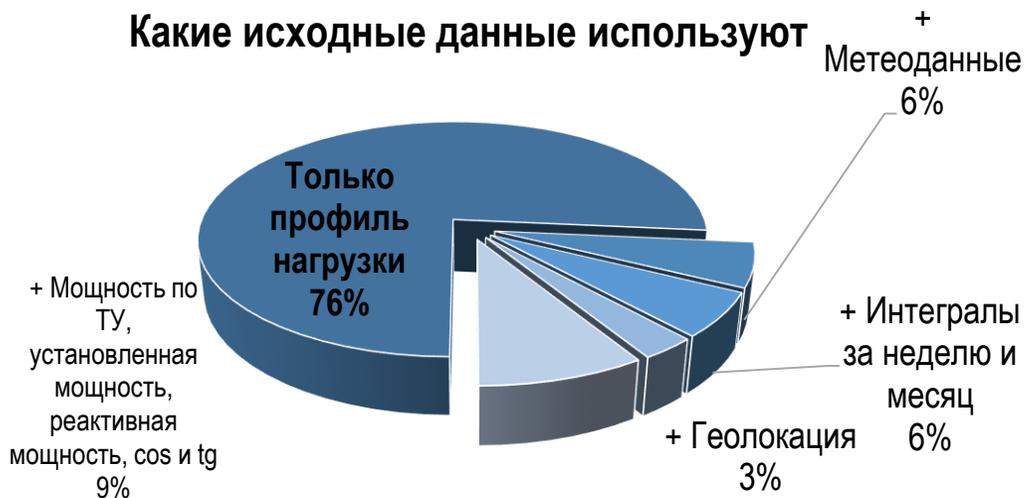
Источник: [Fraud Detection on Power Grids While Transitioning to Smart Meters by Leveraging Multi-Resolution Consumption Data]

- Эффективность алгоритма оценивается, прежде всего, по способности выявлять истинно-положительные значения и не допускать ложно-отрицательных значений. Далее оцениваются ошибки второго рода – ложно-положительные результаты вместо истинно-отрицательных



ИСХОДНЫЕ ДАННЫЕ, МЕТРИКА, ГЛУБИНА РЕТРОСПЕКТИВЫ И ЧАСТОТА ДИСКРЕТИЗАЦИИ

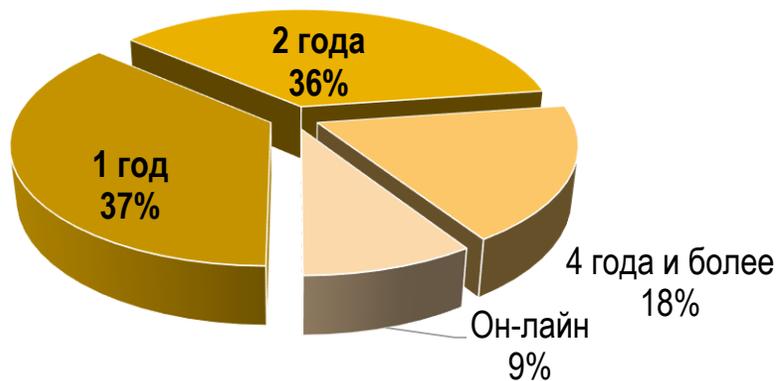
Какие исходные данные используют



Основная метрика

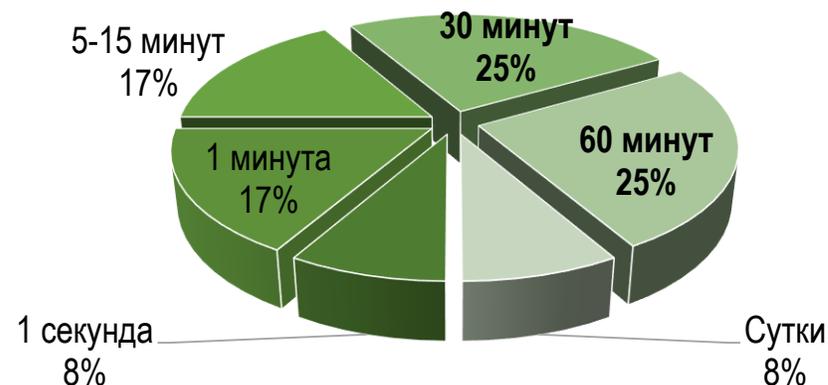


Глубина ретроспективы



Источник:
[Performance
Analysis of
Electricity Theft
Detection for the
Smart Grid: An
Overview]

Дискретность профиля электропотребления



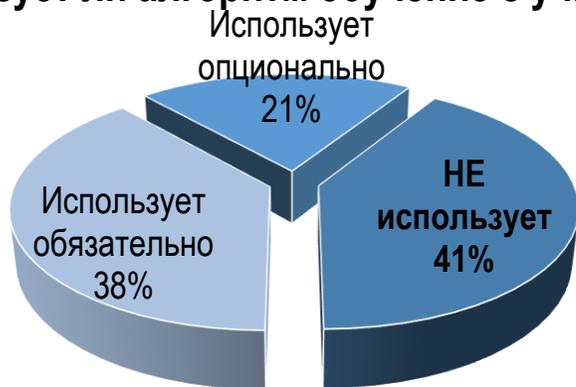


НЕКОТОРЫЕ ПРАКТИЧЕСКИЕ ВОПРОСЫ ИД И ОБУЧЕНИЯ НЕЙРОННОЙ СЕТИ

Используют ли показания балансового счетчика на головном участке как ИД?

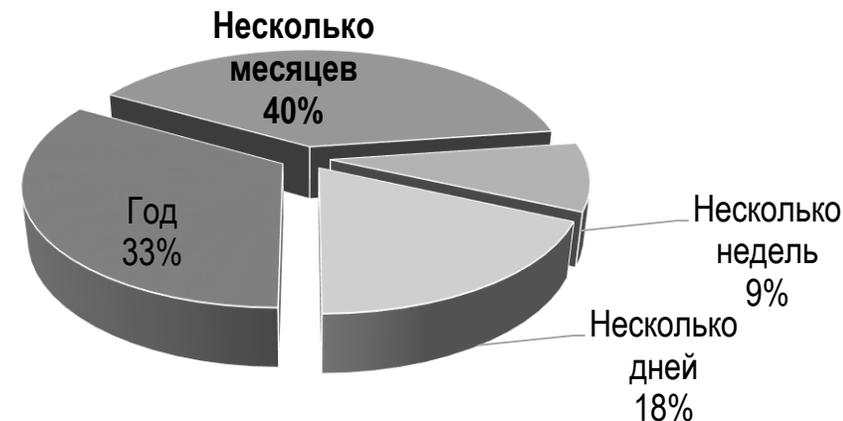


Использует ли алгоритм обучение с учителем?

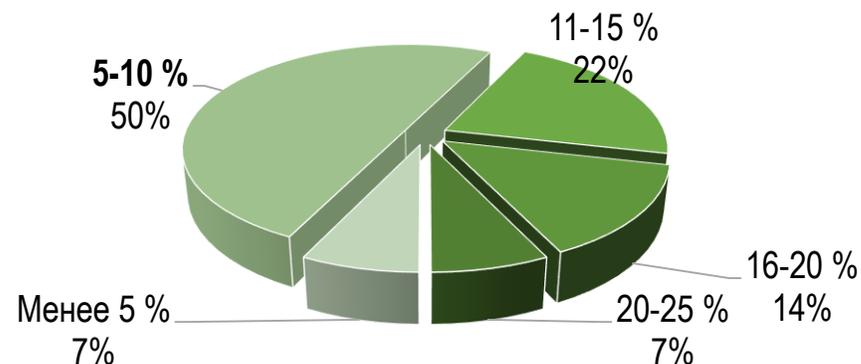


Источники:
[Review of non-technical loss detection methods, Performance Analysis of Electricity Theft Detection for the Smart Grid: An Overview, Non-technical losses: A systematic contemporary article review]

Время работы алгоритма до выявления НПЭЭ



Каков процент искаженных данных в тестовых выборках?





ОСНОВНЫЕ ИМИТАЦИОННЫЕ МАТЕМАТИЧЕСКИЕ МОДЕЛИ КРАЖ ЭЛЕКТРОЭНЕРГИИ

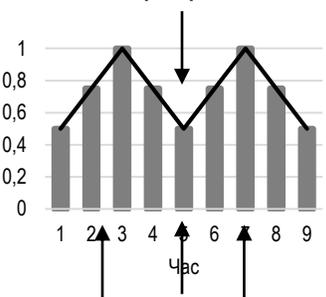
Модель	Описание и смысл	Подход к выявлению	Эффективная NN
$\tilde{x}_t = \alpha x_t, 0.2 < \alpha < 0.8$	Электропотребление в определенный или случайный интервал учета умножается на фиксированный понижающий коэффициент	На фиксированную величину снижается электропотребление в каждый из интервалов учета по сравнению с «типовым» по форме профилем. Обычно в часы полупик/пик или последовательные периоды целиком	CNN, AE
$\tilde{x}_t = \alpha_t x_t, 0.2 < \alpha_t < 0.8$	Электропотребление в определенный или случайный интервал учета умножается на понижающий коэффициент, индивидуальный для данного интервала учета	Искажается профиль электропотребления по сравнению с «типовым» вплоть до отсутствия «типового» профиля. Выявляется наличие некоего математического распределения величины понижающих коэффициентов (нормальное, равномерное, бета и т.д.)	CNN, DNN, AE
$\tilde{x}_t = \beta x_t, \beta = \begin{cases} 1 & \text{if } t_1 < t < t_2 \\ 0 & \text{otherwise} \end{cases}$	Электропотребление равно 0 в определенные диапазоны интервалов учета (чаще всего, пиковые часы) или случайные интервалы учета	Систематические провалы электропотребления до 0 и искажается профиль электропотребления по сравнению с «типовым»	CNN, DNN, AE
$\tilde{x}_t = \text{inverse}(x_t)$	Сохраняется интегральное значение профиля за коммерческий интервал, но профиль сдвигается на 4-12 ч. Возможно или при апостериорной сдаче показаний, или подмена в темпе процесса при высокой суточной стабильности электропотребления	Форма профиля электропотребления за период без изменений, но профиль смещён во времени (нарушена временная регрессия). Если сдвиг дискретный, то в момент сдвига нарушена автокорреляция с предыдущими периодами. Если величины электропотребления за интервалы учета переставлены случайным образом или сдвиг непрерывный, то см. модель №2.	DNN, GRU
$\tilde{x}_t = \bar{x}$	Электропотребление в определенный или случайный интервал учета принимается равным среднему за определенный период времени	Равенство с интегральным значением электропотребления за месяц, за неделю, за сутки; за n предыдущих интервалов учета; за k самых меньших величин электропотребления в предыдущие месяц, неделю, сутки или n предыдущих интервалов учета; за внепиковые часы. Обычно в часы полупик/пик	GRU, LSTM, DNN
$\tilde{x}_t = \alpha_t \bar{x}, 0.2 < \alpha_t < 0.8$	Электропотребление в определенный или случайный интервал учета принимается пропорционально среднему за определенный период времени с занижением на случайный коэффициент	Автокорреляция с интегральным значением электропотребления за месяц, за неделю, за сутки; за n предыдущих интервалов учета; за k самых меньших величин электропотребления в предыдущие месяц, неделю, сутки или n предыдущих интервалов учета; за внепиковые часы. Обычно в часы полупик/пик	CNN, AE + GRU CNN, AE + LSTM

+Проверка по (не)балансу на участке сети в час t - любая NN при условии представления профиля (не)баланса в подходящем виде



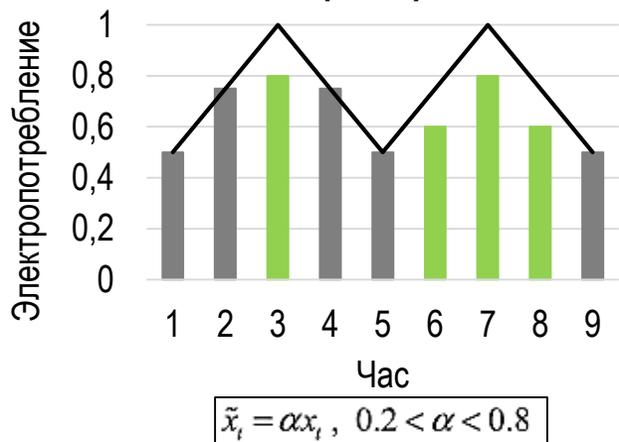
ГРАФИЧЕСКАЯ ИЛЛЮСТРАЦИЯ К ИМИТАЦИОННЫМ МОДЕЛЯМ КРАЖ ЭЛЕКТРОЭНЕРГИИ

Форма графика
(типовой профиль
электропотребления) -
авторегрессия

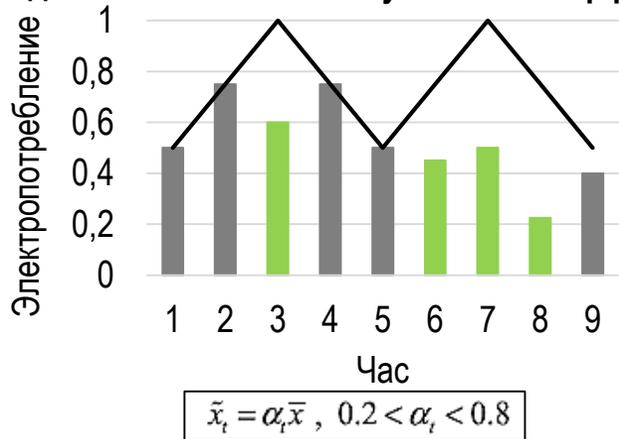


Типовые значения
электропотребления по
часам – временная
регрессия

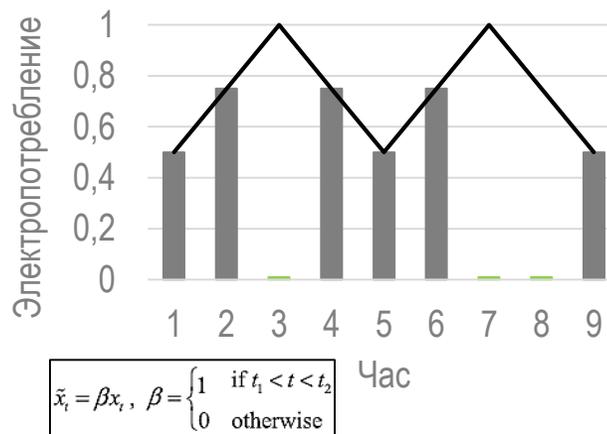
Занижение в часы пик, случайные часы или
диапазоны часов на *фиксированный* коэфф-т



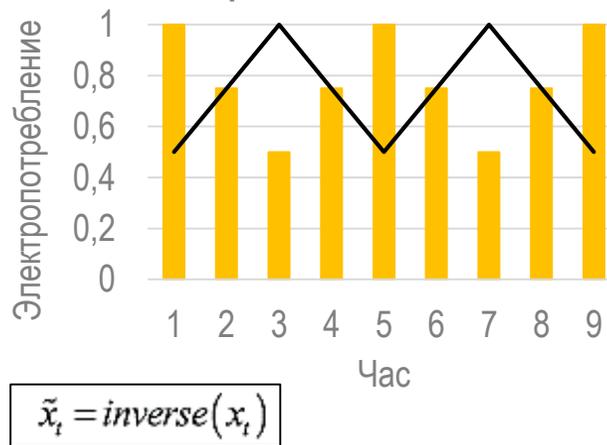
Занижение в часы пик, случайные часы или
диапазоны часов на *случайный* коэфф-т



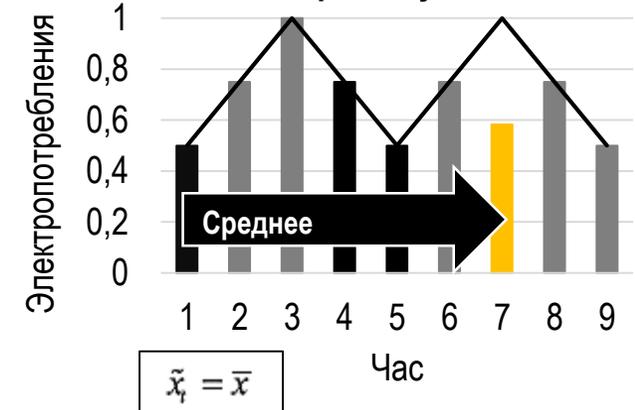
Провалы до 0 в часы пик, случайные
часы или диапазоны часов



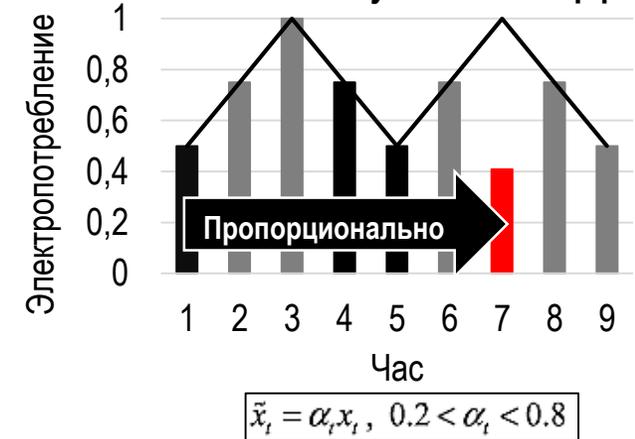
Сдвиг графика во времени вплоть до
полной инверсии по часам пик-внепик



Подмена значения на среднее нескольких
небольших предыдущих значений



Подмена значения на среднее с
занижением на *случайный* коэфф-т





ОТКРЫТЫЕ НАБОРЫ ДАННЫХ ДЛЯ ПОИСКА НПЭЭ В РАЗЛИЧНЫХ ИССЛЕДОВАНИЯХ

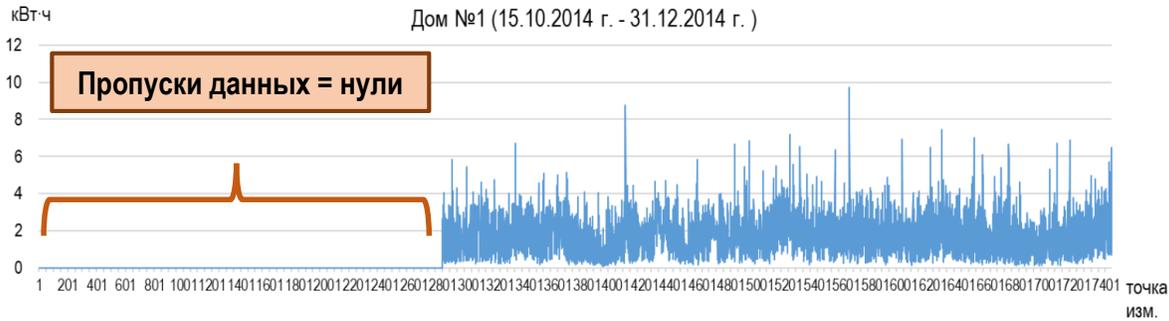
Dataset	Number of customers	Observed period	Sampling resolution	Download pages
UMass Smart* dataset [35]	400+ anonymous homes	Over 2 years	1 minute	traces.cs.umass.edu/index.php/smart/smart
SGCC dataset [36]	42372 users	Over 2 years	1 day	github.com/henryRDlab/ElectricityTheftDetection
Irish Smart Energy Trial (ISET) dataset [41]	5000+ residential, industrial and commercial customers	535 days	30 minutes	www.ucd.ie/issda/data/commissionforenergyregulationcer/
Individual household electric power consumption dataset [42]	One house	Nearly 4 years	1 minute	archive.ics.uci.edu/ml/datasets/Individual+household+electric+power+consumption
Electricity Load Diagrams dataset [43]	370 customers	Nearly 4 years	15 minutes	archive.ics.uci.edu/ml/datasets/ElectricityLoadDiagrams20112014
Load Profiles for TMY3 Locations [44] dataset	from 16 commercial building types and residential buildings in all TMY 3 locations in U.S.	1 year	1 hour	openei.org/doe-opendata/dataset/commercial-and-residential-hourly-load-profiles-for-all-tmy3-locations-in-the-united-states
Solar Power Data for Integration Studies [45]	6,000 simulated PV plants	1 year	5 minutes	www.nrel.gov/grid/solar-power-data.html
Power Systems Test Case Archive [37] [74, 75]	-	-	-	(1) labs.ece.uw.edu/pstca/ (2) site.ieee.org/pes-testfeeders/resources/ (3) icseg.itl.illinois.edu/power-cases/data.london.gov.uk/dataset/smartmeter-energy-use-data-in-london-households
Low Carbon London smart meter trials dataset [46]	5567 households	Over 2 years	30 minutes	data.london.gov.uk/dataset/smartmeter-energy-use-data-in-london-households
Open Energy Information (OpenEI) [47]	936 residential customers	1 year	60 minutes	en.openei.org/datasets/dataset
Pecan Street dataset [48]	1000+ customers	-	Real-time	www.pecanstreet.org/work/energy/data.gov.au/dataset/0f3d60db-bd63-419e-9cd9-0a663f3abbc9
AER dataset [49]	25 households	2 years	30 minutes	

- Данные соответствуют реальным объектам;
- Преднамеренные кражи электроэнергии, по мнению научного сообщества, в этих наборах данных отсутствуют (кроме SGCC), но имеются ошибки, сбои и погрешности учёта электроэнергии;
- Для добавления НПЭЭ в наборы данных используется имитационное моделирование краж электроэнергии.

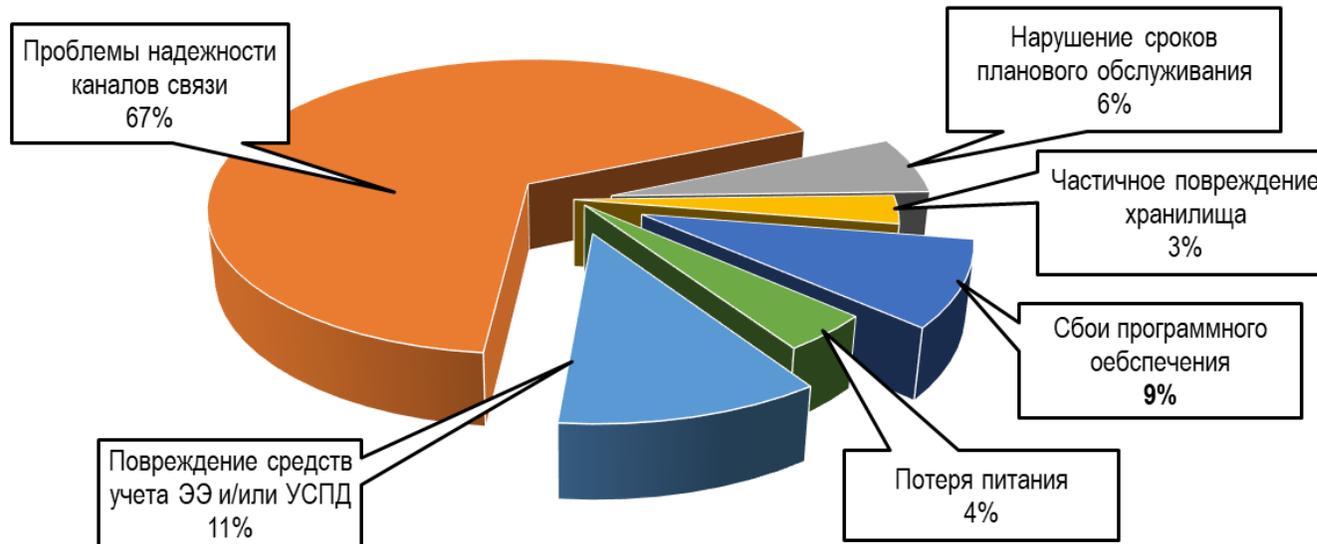
Источник: [Performance Analysis of Electricity Theft Detection for the Smart Grid: An Overview]



MIT UMASS DATASET (15 МИН)



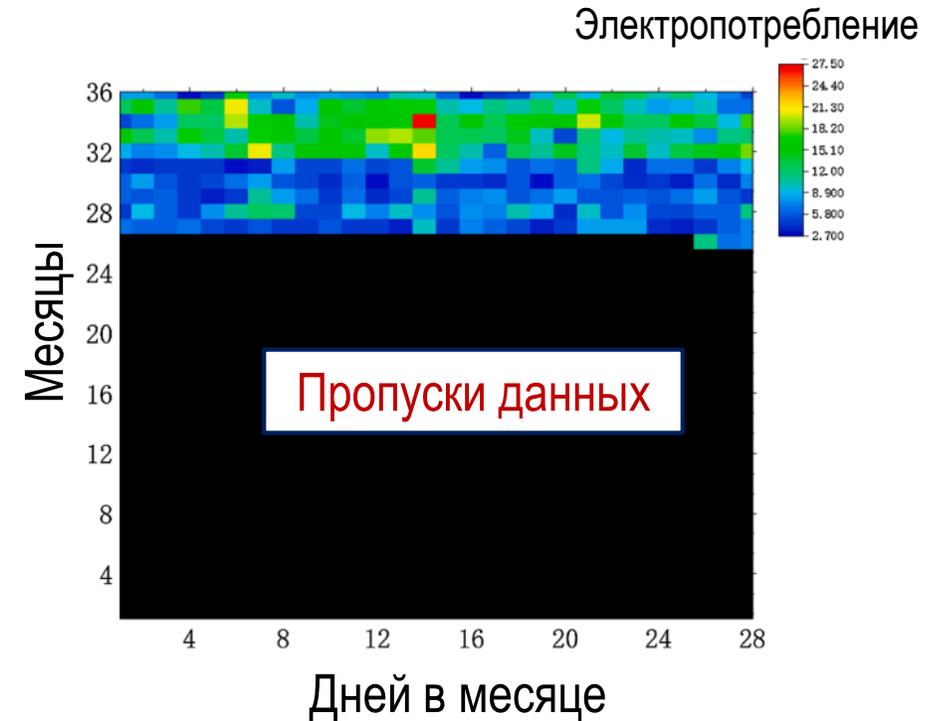
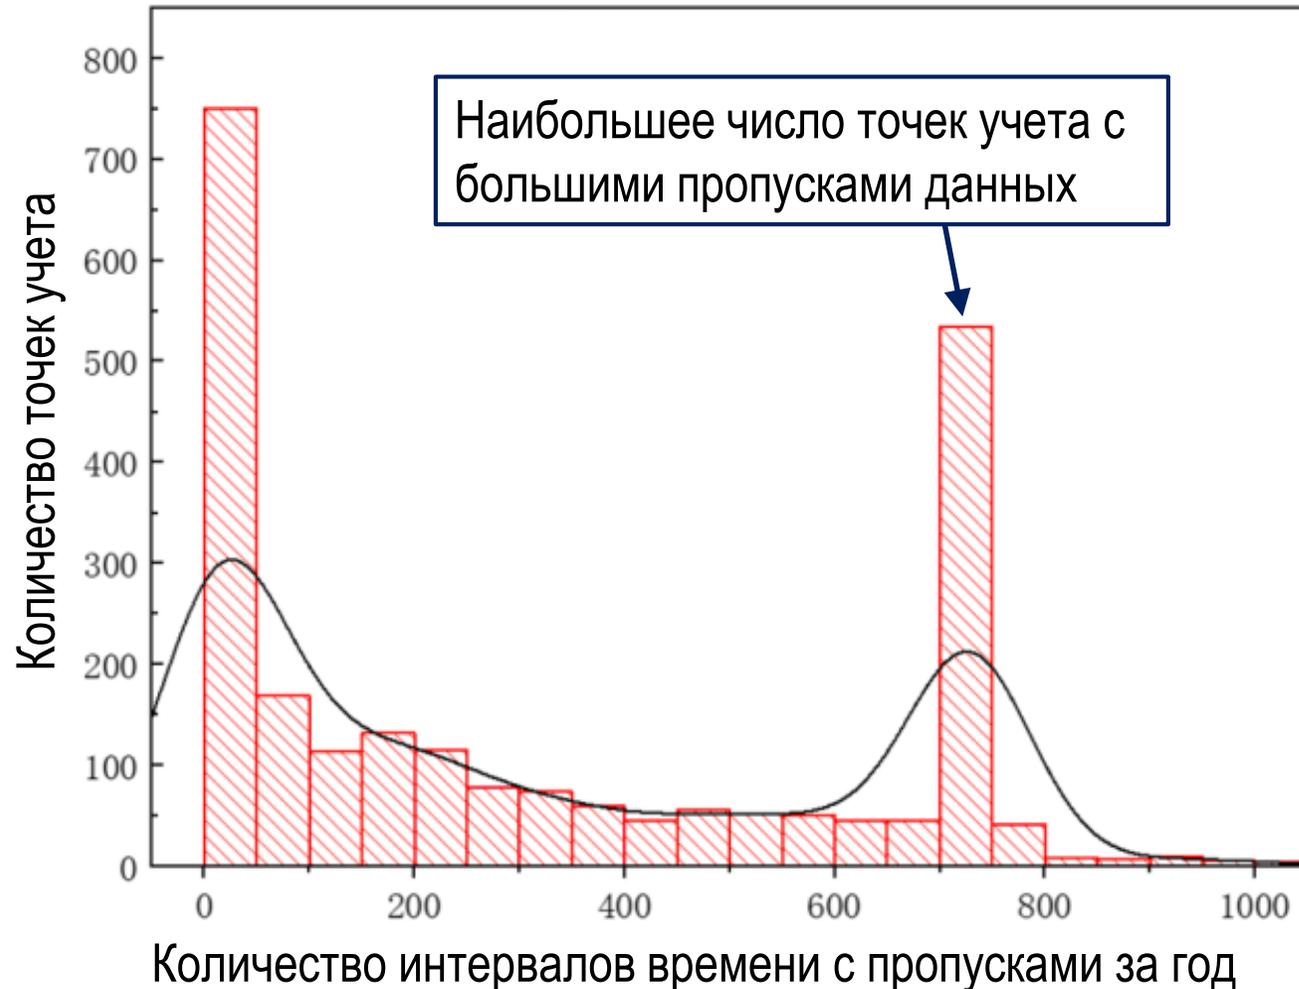
ELECTRIC LOAD DIAGRAM DATASET (15 МИН)



**Статистика причин
появления «плохих данных»**



ПРОПУСКИ ДАННЫХ «ГЛАЗАМИ» СВЁРТОЧНОЙ НЕЙРОННОЙ СЕТИ



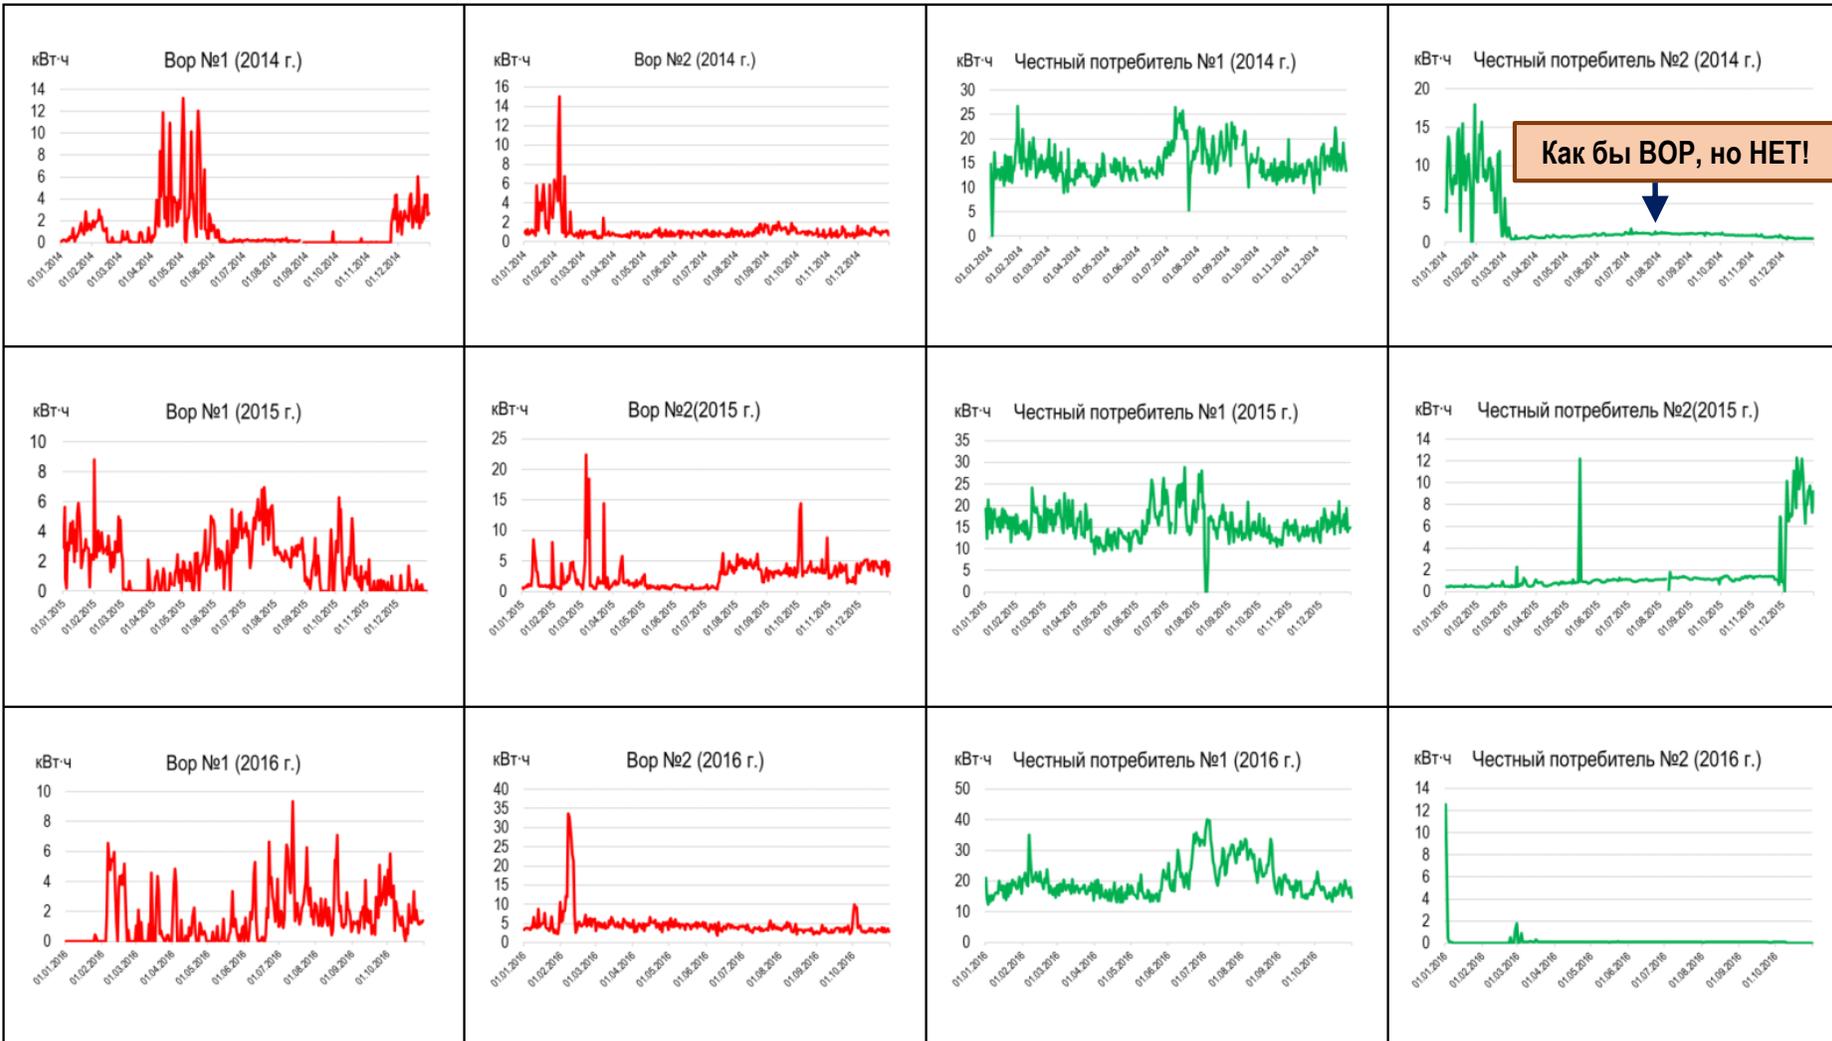
Удаление **X** из выборки всех данных от точки учета, имеющей большие пропуски измерений

Проблема: если сравнение производится между потребителями, удаление необходимо производить у всех потребителей



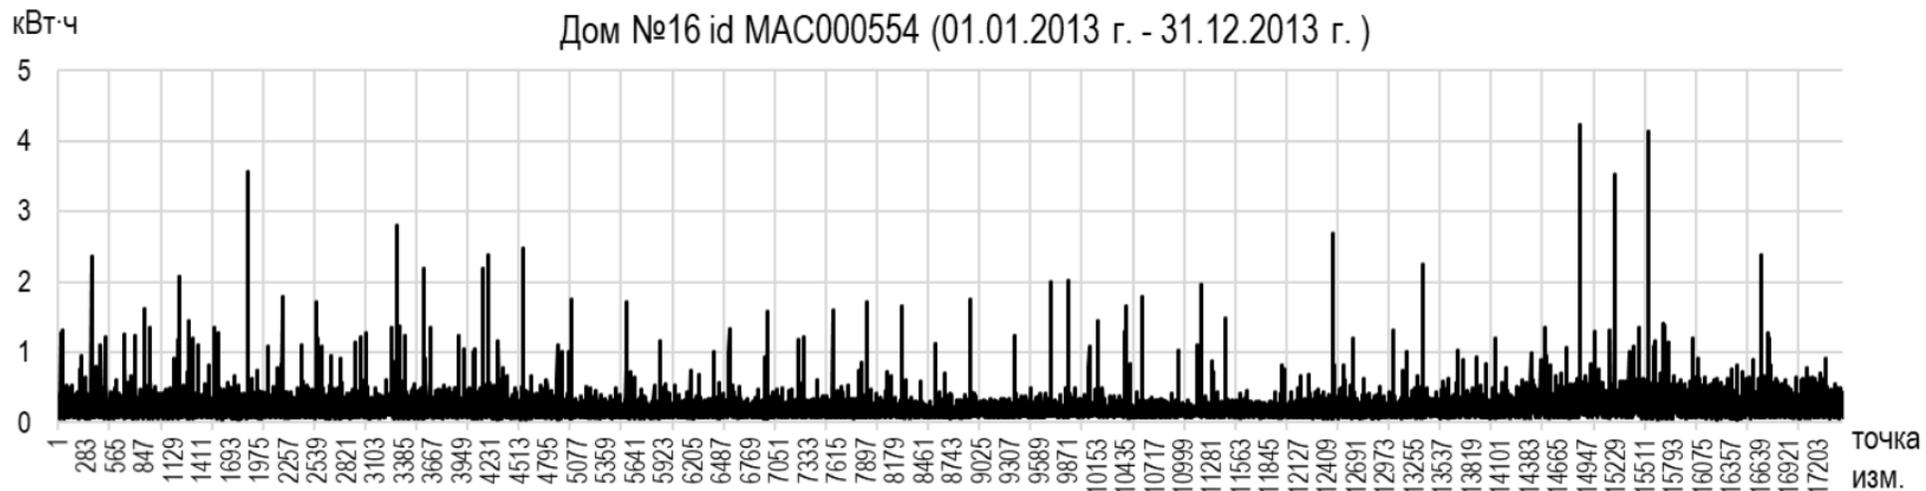
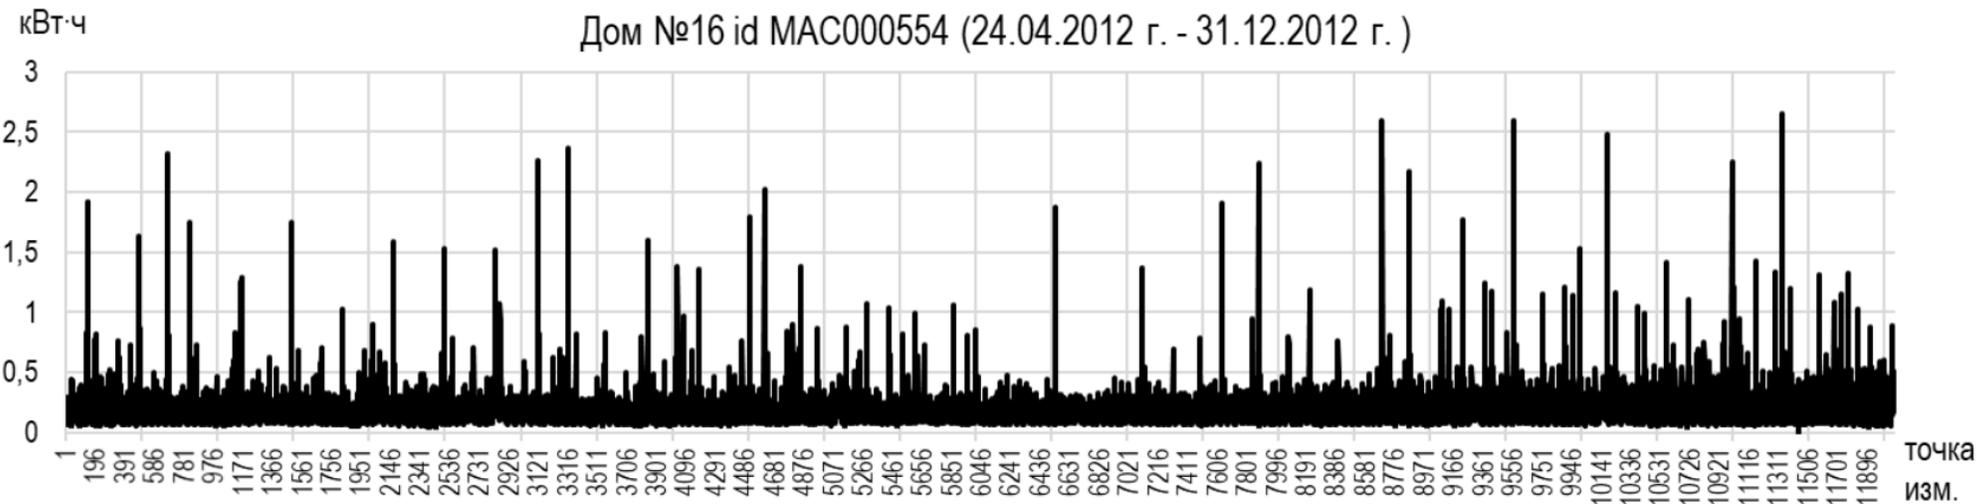
STATE GRID CORPORATION OF CHINA DATASET (1 Ч, РАЗМЕТКА)

- Наличие большого числа потребителей со слабо выраженной сезонностью в электропотреблении;
- Существенные различия в годовых графиках между однотипными потребителями;
- В некоторых случаях поведение честного потребителя качественно не отличается от ВОРа, но есть нюансы;
- В основном, **в разы** среднегодовое электропотребление у ВОРов ниже, чем у честного потребителя





LOW CARBON LONDON SMART METER TRIAL DATASET (30 МИН)



- Нет типовых годовых сезонных максимумов;
- Максимумы электропотребления локализованы по неделям;
- Недельные максимумы соответствуют вторникам и пятницам;
- Небольшая нагрузка, соответствующая жилым домам, порядка 400-800 Вт.



НОРМАЛИЗАЦИЯ ИСХОДНЫХ ДАННЫХ. 1

Назначение: обеспечивает выравнивание (масштабирование) данных в пределах одного интервала

Вариант 1 (MIN-MAX масштабирование): «растягивание» измерений в диапазоне $[a, b]$.

$$X' = a + \frac{X - X_{\min}}{X_{\max} - X_{\min}} (b - a)$$



Простота реализации



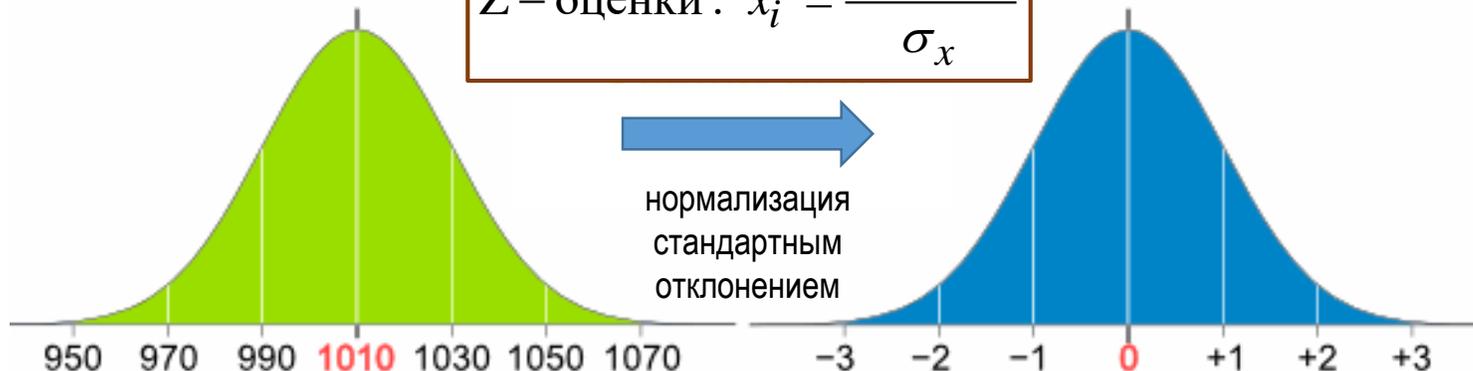
Аномальные значения «растягивают» диапазон, а значит, нормализованные значения концентрируются вблизи 0

Вариант 2. Стандартизация (Z-нормализация): для получения среднего значения 0 и стандартного отклонения 1.

$$Z\text{-оценки: } x_i' = \frac{(x_i - \bar{X})}{\sigma_x}$$



нормализация
стандартным
отклонением



Слабая чувствительность к ошибкам

если:

- Z-оценка < 0 , то x ниже средней
- Z-оценка > 0 , то x выше средней



НОРМАЛИЗАЦИЯ ВХОДНЫХ ДАННЫХ. 2

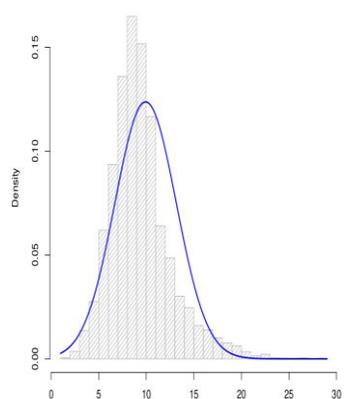
Назначение: обеспечивает коррекцию симметрии распределения случайной величины

Область применения: только для распределений, близких к нормальному

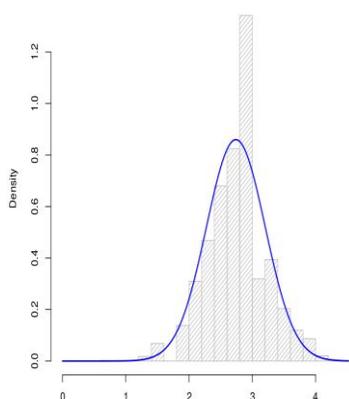
Методы приведения «ненормальной» статистики к норм.:

- Метод **Бокса-Кокса** (Box-Cox): $x'_i = \frac{x_i^\lambda - 1}{\lambda}$ для $\lambda \neq 0$ и $x'_i = \log(x)$ для $\lambda = 0$.

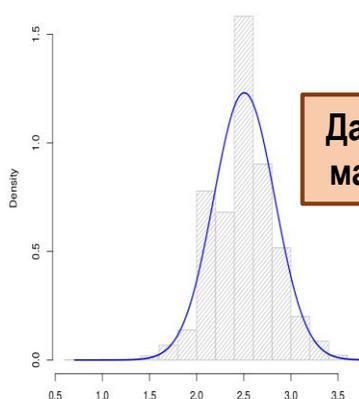
- Преобразование **Йео-Джонсона** (Yeo-Johnson)



Исходное

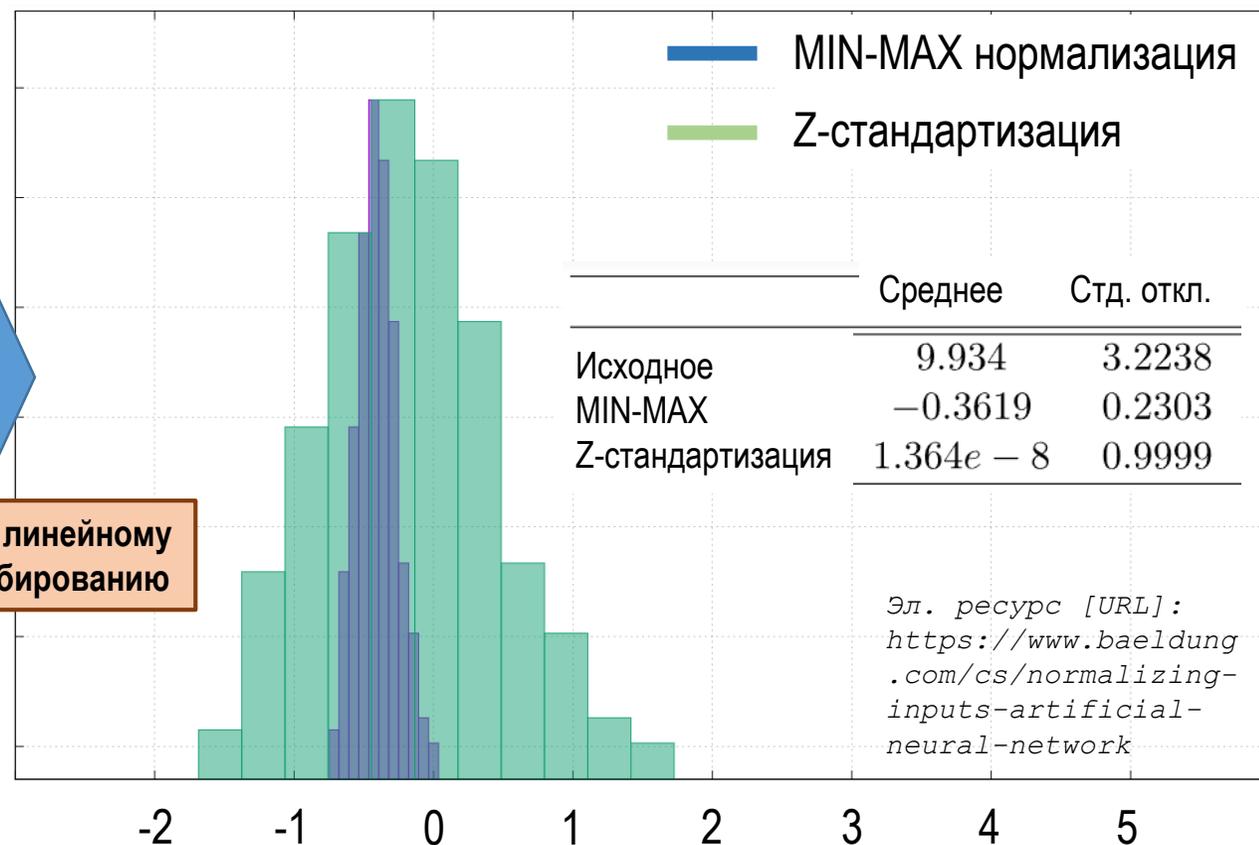


Бокс-Кокс



Йео-Джонсон

Далее к линейному масштабированию

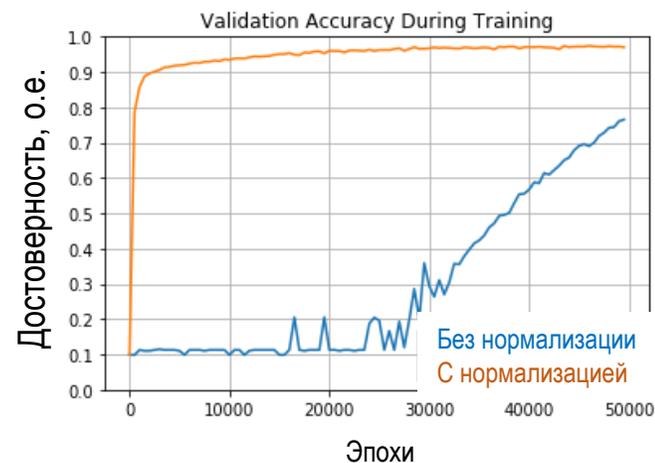
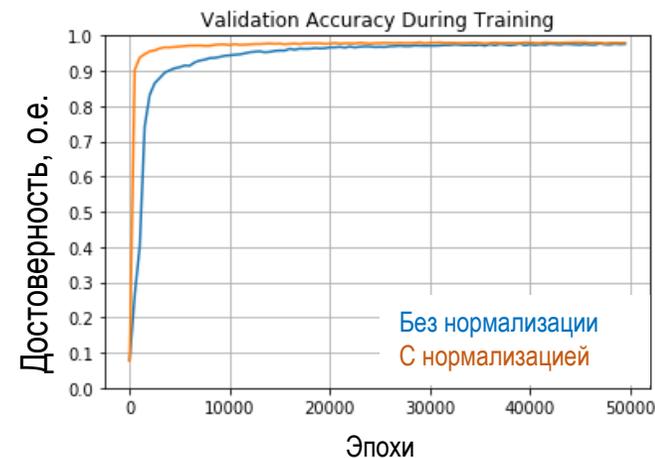
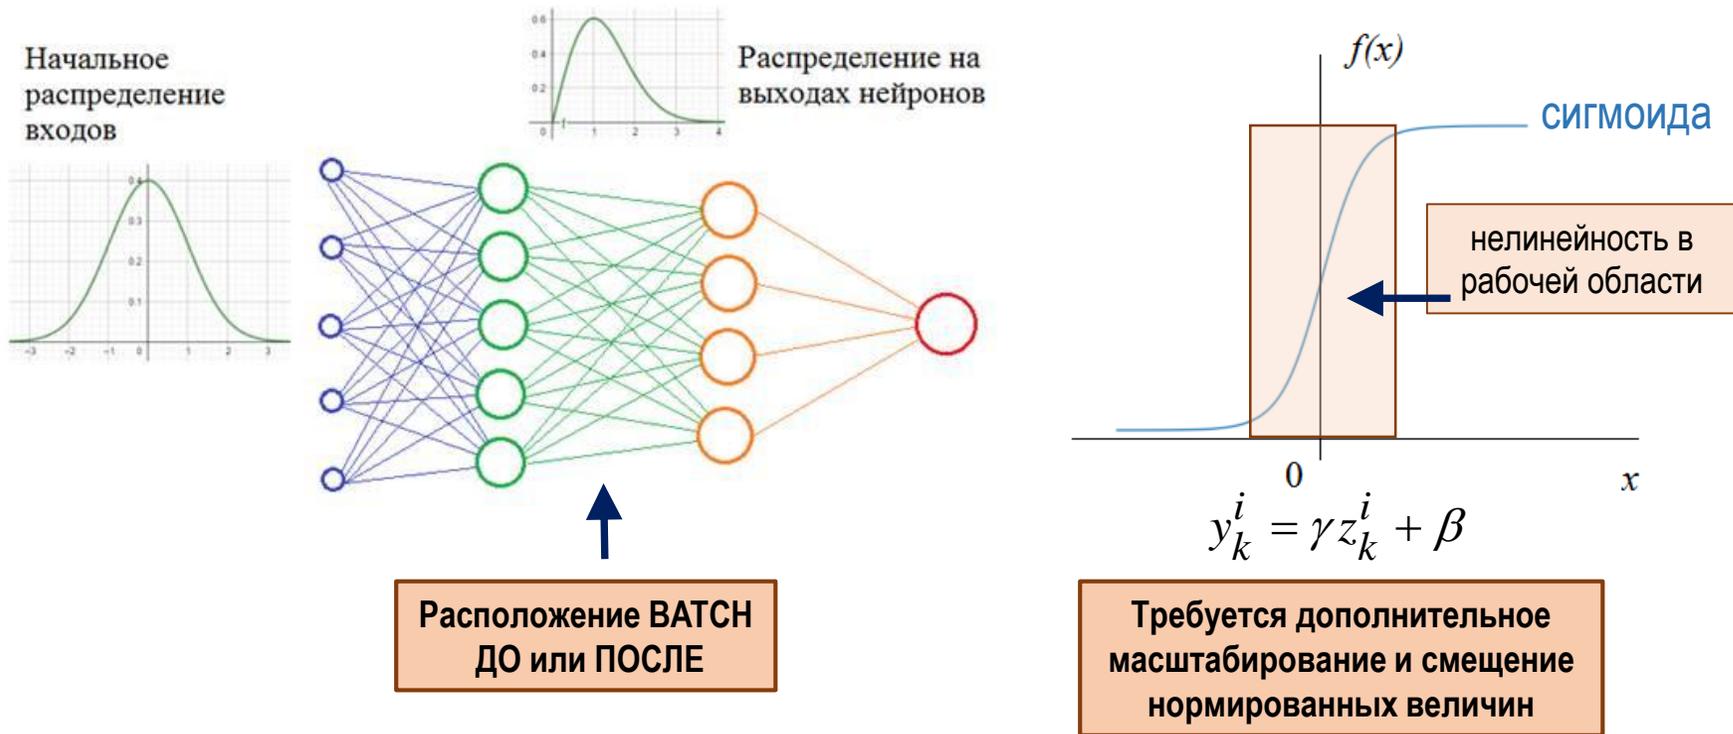


Эл. ресурс [URL]:
<https://www.baeldung.com/cs/normalizing-inputs-artificial-neural-network>



ПАКЕТНАЯ (BATCH) НОРМАЛИЗАЦИЯ КАК ВСТРОЕННЫЙ В ИНС ИНСТРУМЕНТ

Назначение: обеспечивает решение проблемы внутреннего ковариационного сдвига (разные MO и D)

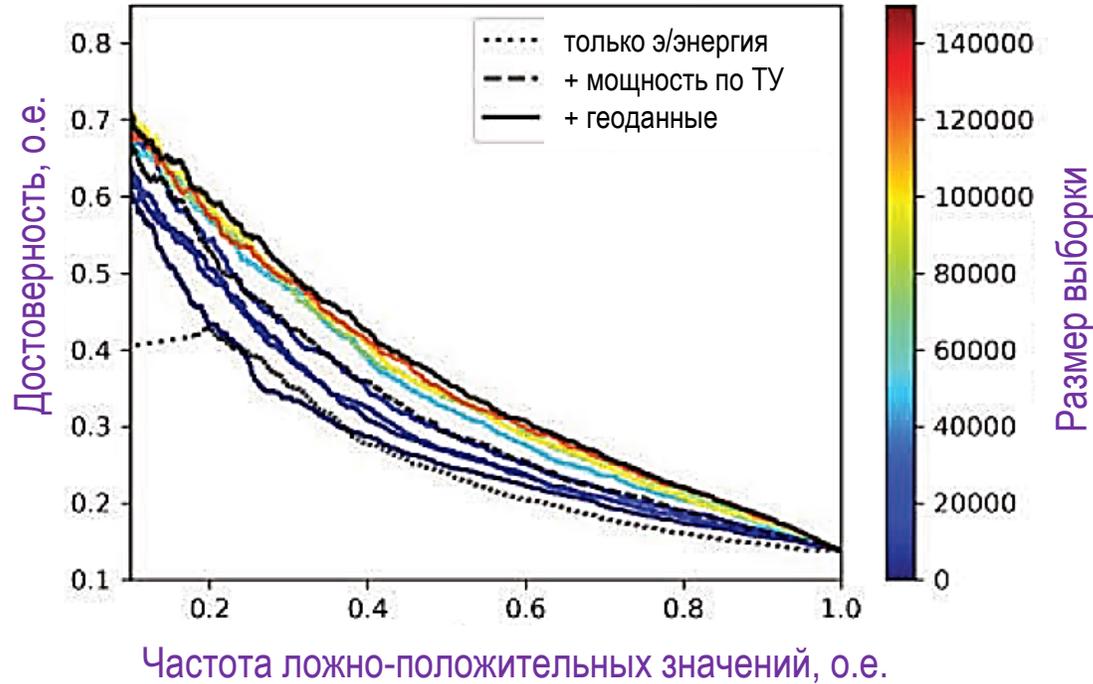


Влияние: значительное ускорение обучения ИНС, предотвращение переобучения

Популярный метод нормализации: пакетная Z-нормализация



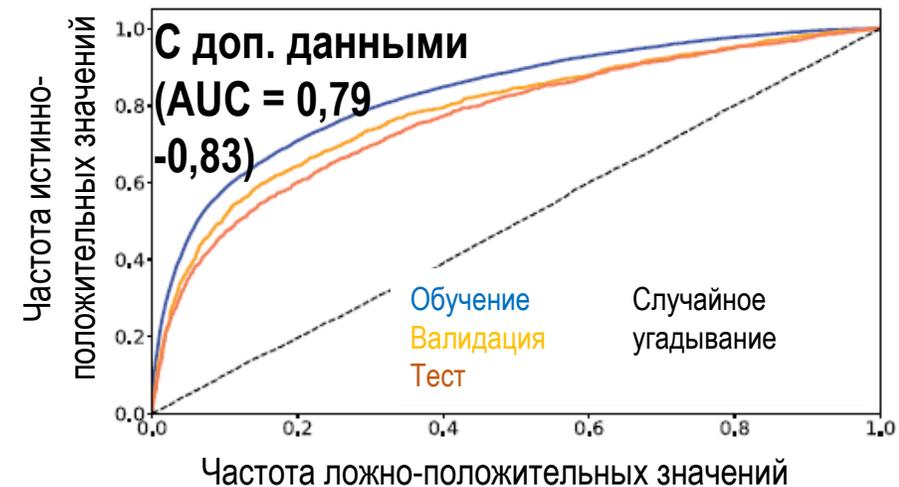
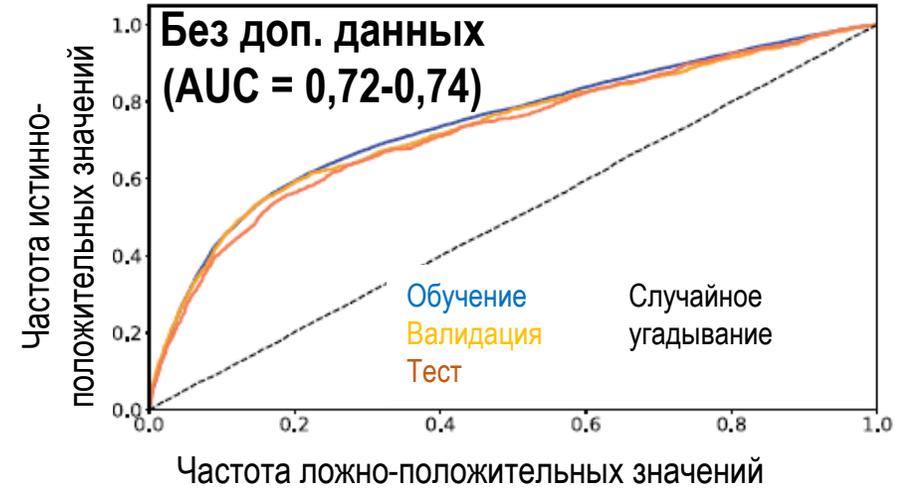
КАК ВЛИЯЕТ КОЛИЧЕСТВО ДАННЫХ И ДОПОЛНИТЕЛЬНЫЕ ТИПЫ ДАННЫХ НА РЕЗУЛЬТАТ?



← Источник: [NTL detection: overview of classic and DNN-based approaches on a labeled dataset of 311k customers]

Источник: [Hybrid deep neural networks for detection of Non-Technical losses on electricity smart meters] →

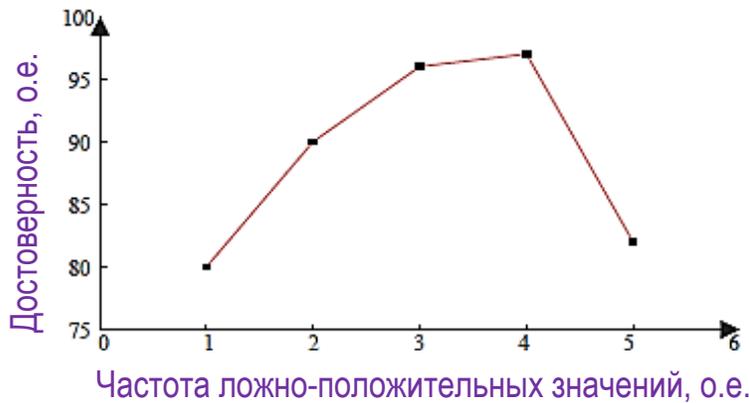
- Дополнительные данные повышают чувствительность алгоритма на 7-10% и снижают частоту ложно-положительных значений на 3-5 %;
- Эффект более выражен при больших исходных выборках.



Дополнительные исходные данные		
% нулевых измерений	Округ (муниципалитет)	Тип счетчика
% потерь измерений	Мощность по ТУ	Версия прошивки
Сезон года	Номер тарифа	Год выпуска счетчика
Координаты	Расположение счетчика	ОКВЭД для юр.лиц



ИЗВЛЕЧЕНИЕ ВСПОМОГАТЕЛЬНЫХ ПАРАМЕТРОВ ИЗ ПРОФИЛЯ ЭЛЕКТРОПОТРЕБЛЕНИЯ ДЛЯ УСКОРЕННОГО И УЛУЧШЕННОГО ОБУЧЕНИЯ



Источник: [Electricity theft detection in low-voltage stations based on similarity measure and DT-KSVM]

- Теоретически, эффективный метод (глубокого) машинного обучения «самостоятельно» должен выявлять сложные регрессии при наличии достаточной обучающей выборки и эффективных методов обучения;
- Гибридные модели выявления НПЭЭ, созданные для распознавания образов и авторегрессий, обладают меньшими способностями к обобщению зависимостей – по сравнению, например, с DNN;
- В связи с этим в ряде публикаций показана эффективность «принудительного» ввода дополнительных параметров, рассчитанных на основе профиля электропотребления;
- Оптимум количества параметров – 3-4 шт. Параметры не должны образовывать линейные комбинации друг с другом.

**Вспомогательный электрический параметр
(одновременно используются
не более 5 из 10)**

Суточный пик нагрузки в кВт

Доля электропотребления во внепиковое время

Доля электропотребления в пиковое время

Доля неизменного по часам электропотребления

Суточное электропотребление

Число часов максимальных нагрузок

Суточная средняя мощность

Соотношение пика к среднему

Дисперсия мощности за сутки

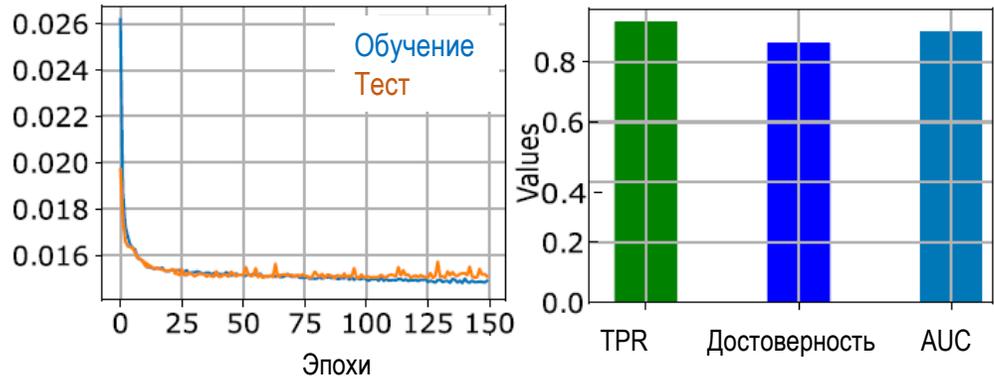
Вариация мощности за сутки



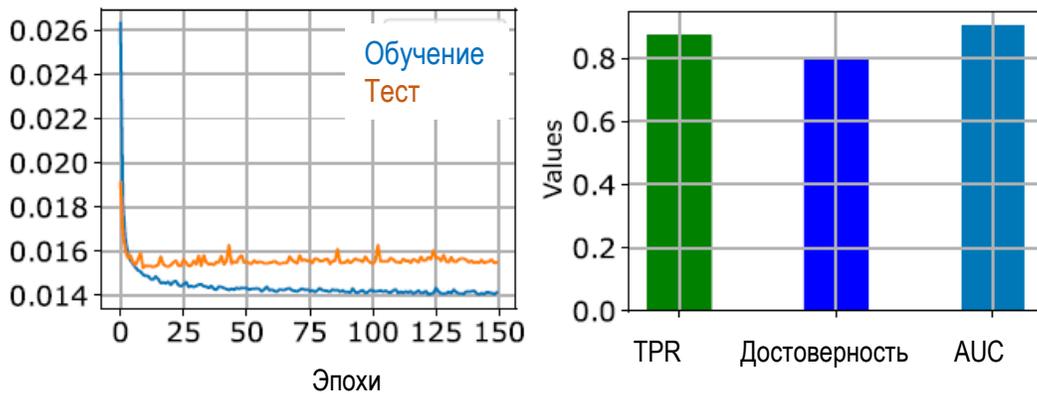
БОЛЬШАЯ ПРОБЛЕМА СБАЛАНСИРОВАННЫХ ИСХОДНЫХ ДАННЫХ

Сбалансированная исходная выборка (PRECON)

Функция ошибки при обучении нейронной сети



Несбалансированная исходная выборка (SGCC)



- При работе на тестовой выборке или реальных данных нейронная сеть в большинстве случаев показывает эффективность меньше, чем при работе на обучающей выборке;
- Данный эффект в виде систематической разницы (bias) 2-3 % в эффективности ИНС между обучением и тестом вызван как новизной данных в тестовой выборке, так и тем, что обучение производится на основе данных, не содержащих НПЭЭ;
- Если количество образцов электропотребления, не содержащих НПЭЭ, существенно превышает количество образцов с НПЭЭ, разница возрастает до 5-7% и продолжает расти вместе с количеством эпох обучения;
- При обучении на несбалансированных ИД возникают наиболее неблагоприятные ложно-отрицательные случаи классификации. При балансировке ИД увеличивается доля ложно-положительных результатов, но снижается доля ложно-отрицательных.

Эффективность классификации до и после балансировки

		Прогнозный класс		Прогнозный класс	
		Честный	Ворует	Честный	Ворует
Фактический класс	Честный	TN 100% (13584)	FP 0% (4)	TN 100% (9619)	FP 0% (13)
	Ворует	FN 5% (65)	TP 95% (1078)	FN 0% (0)	TP 100% (9713)
		Честный	Ворует	Честный	Ворует

Источник: [Robust Data Driven Analysis for Electricity Theft Attack-Resilient Power Grid]



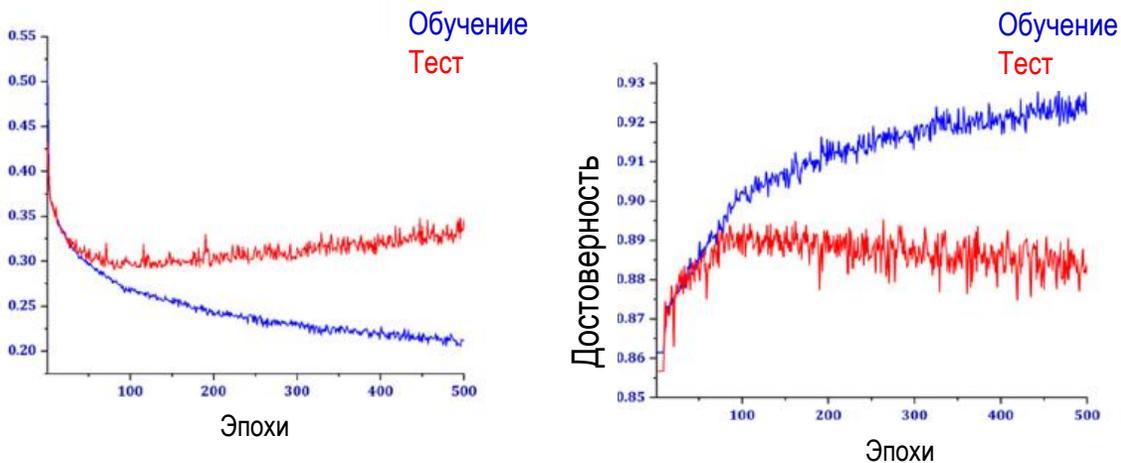
РАЗЛИЧНЫЕ МЕТОДИКИ БАЛАНСИРОВАНИЯ ВЫБОРКИ С ИЗМЕРЕНИЯМИ ЭЭ

Название	Тип	Описание работы алгоритма сэмплинга
Весовые коэффициенты	Выравнивание	Если 5 % измерений содержат НПЭЭ, то их весовой коэффициент при обучении $1/0,05 = 20$, 95 % измерений не содержат НПЭЭ, то их весовой коэффициент при обучении $1/0,95 = 1,05$
RUS	Снижение размера наибольшего из классов	Уменьшает количество измерений без НПЭЭ до количества измерений с НПЭЭ
ROS	Повышение размера наименьшего из классов	Увеличивает количество измерений с НПЭЭ до количества измерений без НПЭЭ
RUS-ROS	Выравнивание	Сокращение/расширение измерений без/с НПЭЭ в равных пропорциях
K-medoids, K-means	Снижение размера наибольшего из классов	Выполняют кластеризацию исходных данных до центроидов/медоидов, принимая их за новые точки (в основном происходит сжатие выборки без НПЭЭ)
Tomek Links	Снижение размера наибольшего из классов	Удаляет точки без НПЭЭ, находящиеся около точек с НПЭЭ (но потеря аномалий)
SMOTE	Повышение размера наименьшего из классов	Синтезирует дополнительные искусственные точки с НПЭЭ между измеренных точек с НПЭЭ
ADASYN	Повышение размера наименьшего из классов	Разновидность SMOTE с количеством синтезируемых точек пропорционально весовому коэффициенту количества точек с НПЭЭ
CBOS	Повышение размера наименьшего из классов	Синтезирует дополнительные искусственные точки с НПЭЭ около измеренных точек с НПЭЭ пропорционально их расстоянию до центроида их кластера

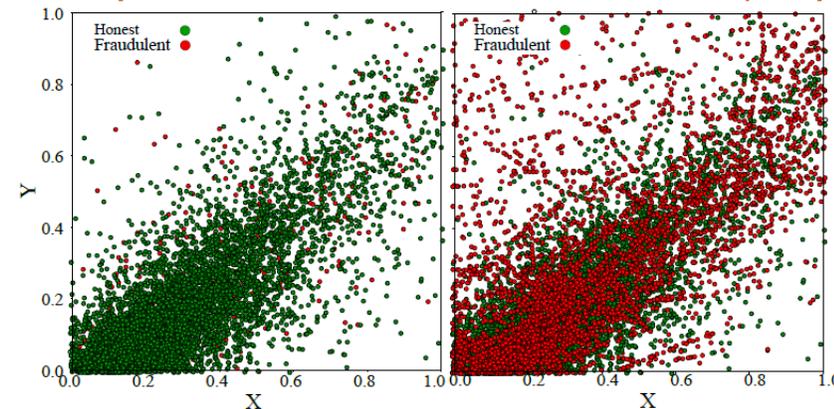


ПРОБЛЕМЫ ИЗМЕНЕНИЯ РАЗМЕРА ИСХОДНОЙ ВЫБОРКИ ВСЛЕДСТВИЕ СЭМПЛИНГА

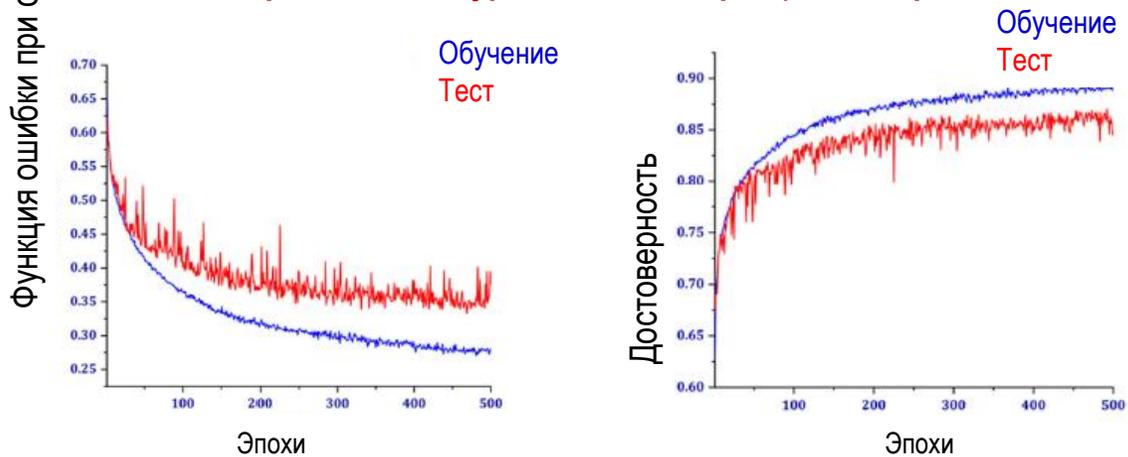
Несбалансированная исходная выборка (достоверность 88-89 %)



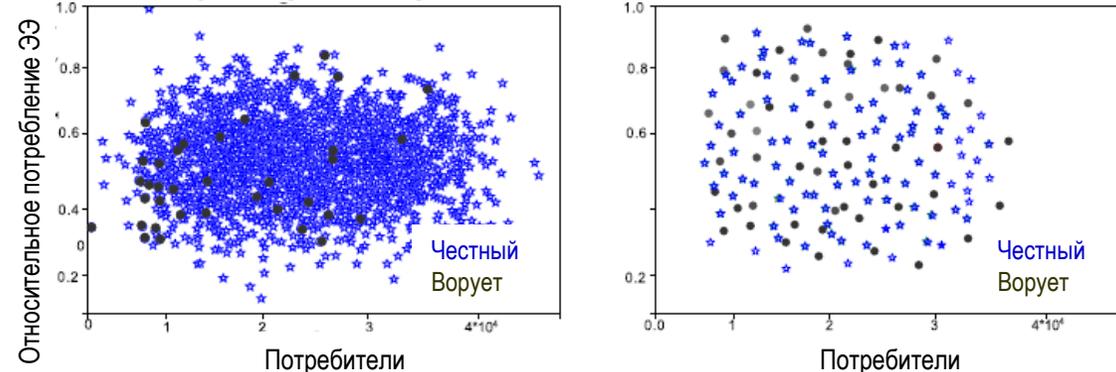
Сбалансированная выборка с тенденцией к переобучению или образованию линейной комбинации весов (выбросы)



Сбалансированная, но урезанная выборка (достоверность 82-84 %)



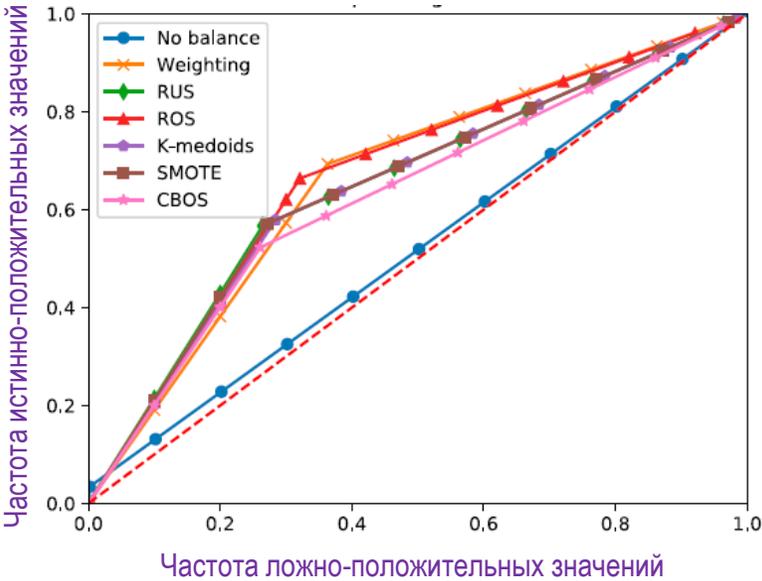
Снижение размера выборки точек без НПЭЭ + добавление точек с НПЭЭ



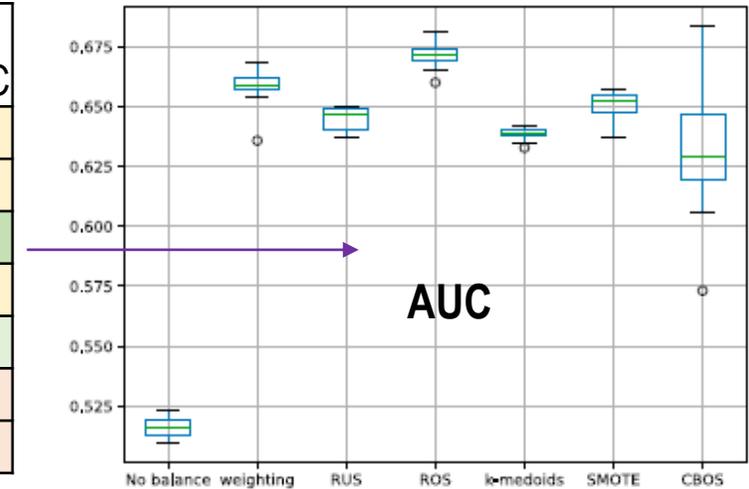
Источники: [Electricity Theft Detection in Smart Grid Systems: A CNN-LSTM Based Approach, Robust Data Driven Analysis for Electricity Theft Attack-Resilient Power Grid, Using GANCNN and ERNET for Detection of Non Technical Losses to Secure Smart Grids]



НАИБОЛЕЕ ЭФФЕКТИВНЫЕ МЕТОДИКИ БАЛАНСИРОВАНИЯ ВЫБОРКИ С ИЗМЕРЕНИЯМИ ЭЭ

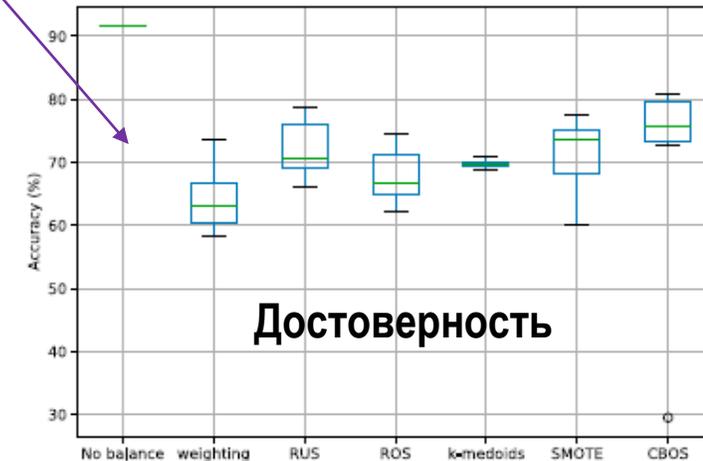


Метод	Время обучения сверточной ИНС	Время работы сверточной ИНС
Без балансировки	44 мин	12,58 с
Весы	46,5 мин	15,85 с
RUS	13 мин	9,13 с
ROS	60 мин	13,52 с
K-medoids	27 мин	11,66 с
SMOTE	8 ч и 12,5 мин	4 мин и 12,71 с
CBOS	8 ч и 2 мин	30,59 с

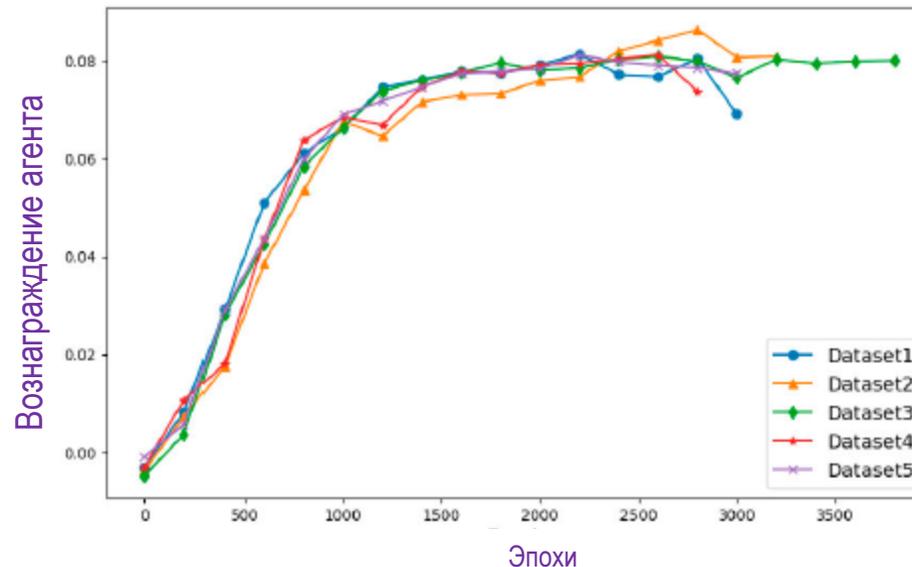
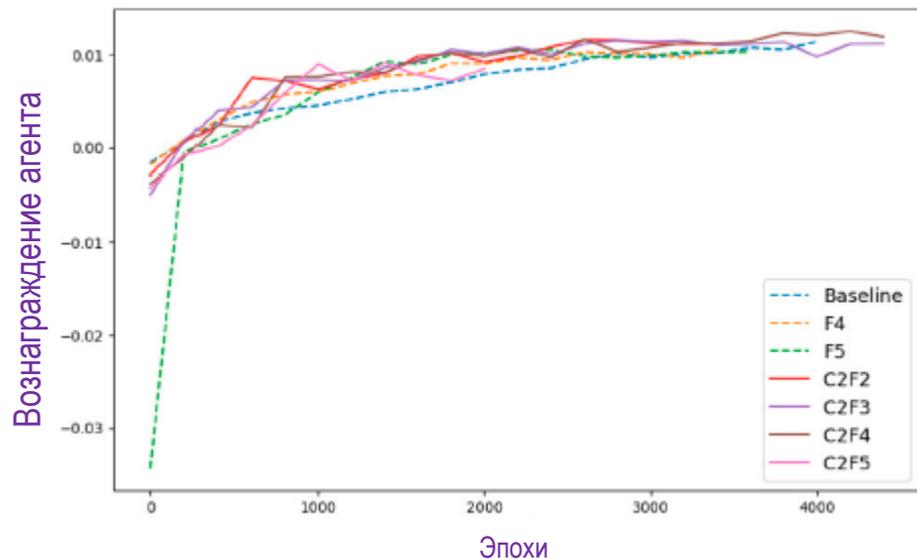


Источник: [Convolutional neural network applied to detect electricity theft: A comparative study on unbalanced data handling techniques]

1. Сложные алгоритмы являются вычислительно затратными без явного улучшения эффективности;
2. Как правило, алгоритмы повышения размера выборки с НПЭЭ из классов показывают большую эффективность. Это связано с тем, что они увеличивают исходную выборку и количество искомых точек с НПЭЭ, в частности. Но провоцируют переобучение нейронной сети и линейную комбинацию весов;
3. При использовании алгоритмов понижения размера выборки без НПЭЭ важно не потерять аномальные образцы электропотребления, не содержащие НПЭЭ, для исключения ложно-положительной классификации.



АЛЬТЕРНАТИВА БАЛАНСИРОВКЕ ИСХОДНЫХ ДАННЫХ. 1



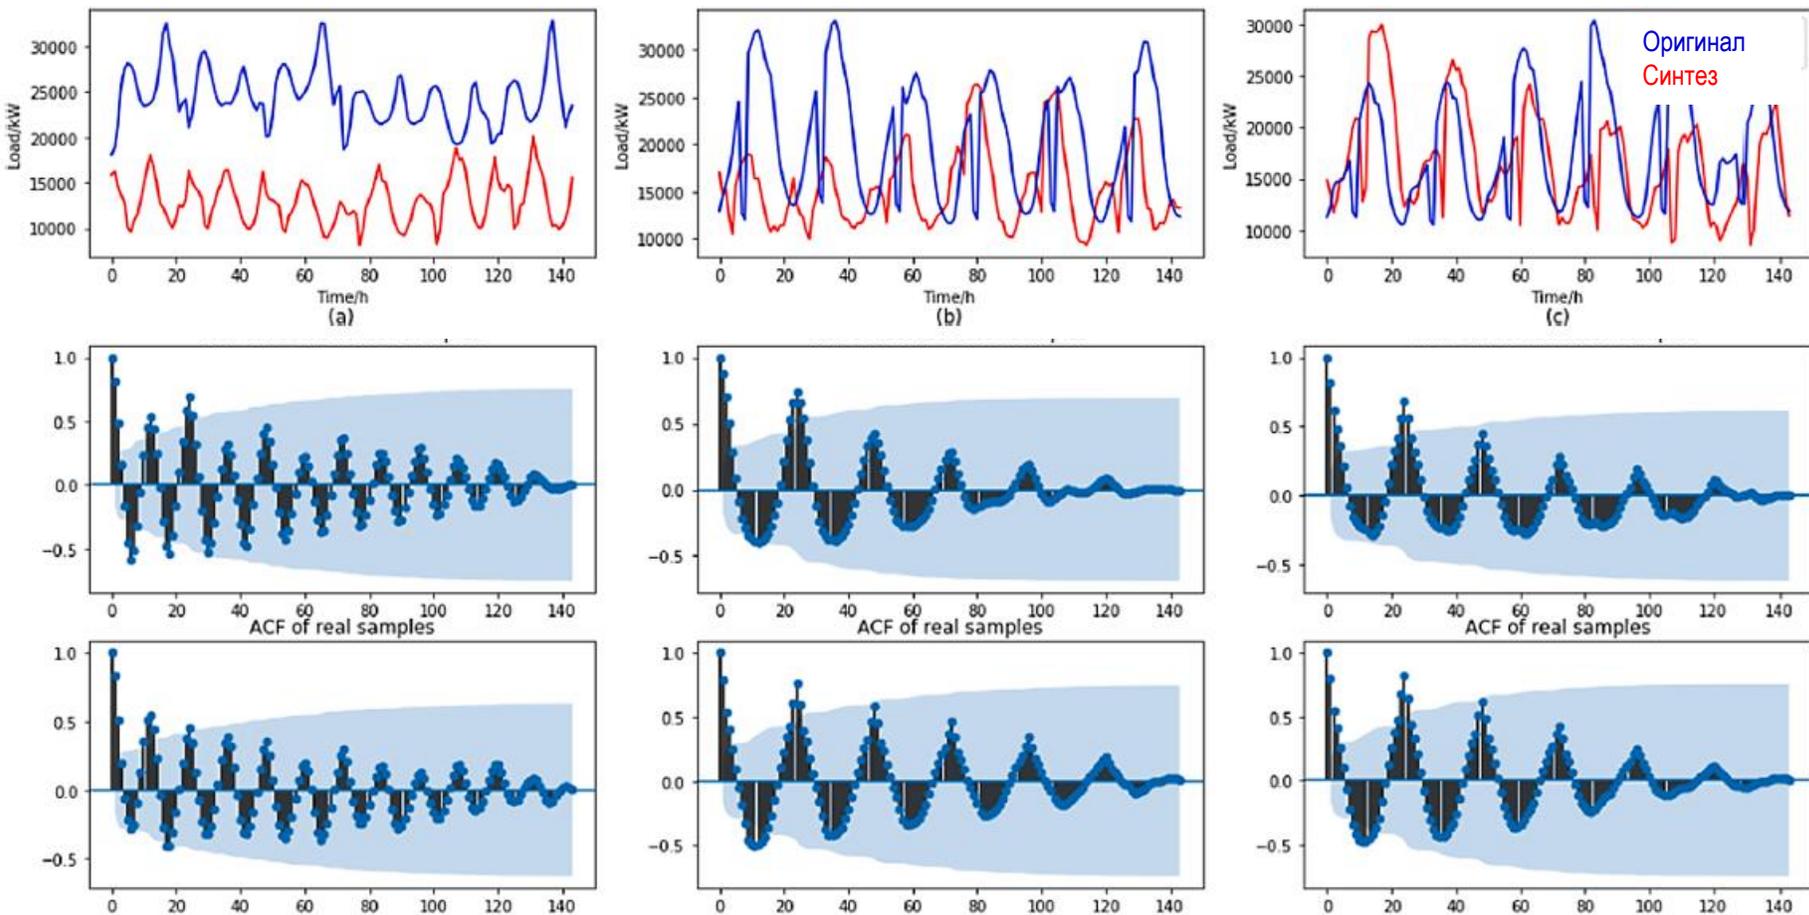
Источник: [Non-Technical Loss Detection Using Deep Reinforcement Learning for Feature Cost Efficiency and Imbalanced Dataset]

$$Q(s, a) = Q(s, a) + \alpha[r + \gamma \max_{a'} Q(s', a') - Q(s, a)]$$

- (Мульти)агентный подход, марковское принятие решений и т.д.
- В качестве основной альтернативы для балансировки исходных данных по количеству достоверных и солежанных НП.ЭЭ изменений а также для повышения робастности алгоритма рассматривается *Обучение нейронной сети с nk* Частота ложно-положительных значений
- В качестве основного метода обучения подкрепления рассматривается Q-обучение на основе критерия оптимальности Беллмана;
- В качестве основной функции полезности Q рассматривается функция среднего вознаграждения (Average Reward);
- Объем ИД оказывает минимальное влияние на эффективность обучения ИНС, важен % ИД с НПЭЭ.

АЛЬТЕРНАТИВА БАЛАНСИРОВКЕ ИСХОДНЫХ ДАННЫХ. 2

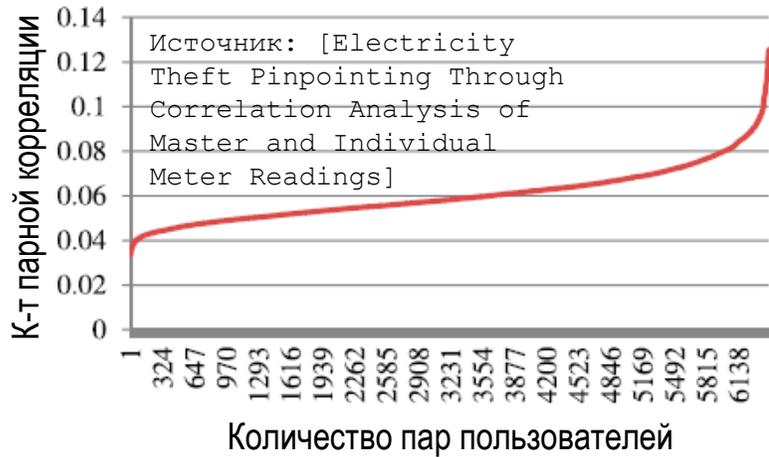
Примеры синтеза выборки с помощью генеративно-состязательной ИНС и их автокорреляция



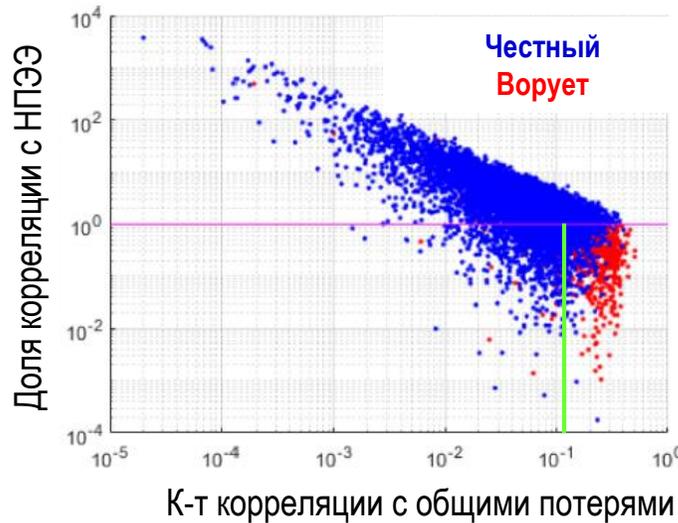
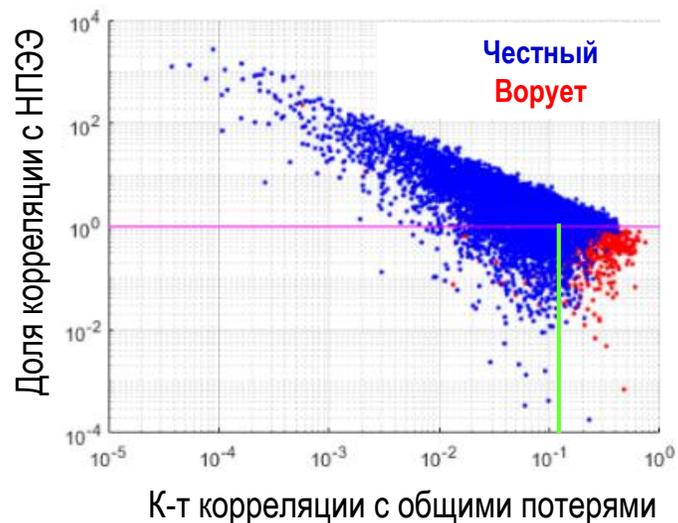
- Для синтеза исходных данных используются генеративно-состязательные нейронные сети;
- Синтезированные части выборки имеют достаточные различия в амплитуде и фазе суточных частей графика электропотребления, но сохраняют форму графика;
- Наиболее важным является сохранение не столько формы графика нагрузки, сколько сохранение его авторегрессионной (автокорреляционной) функции;
- Для обучения генеративно-состязательной сети может потребоваться применение алгоритмов изменения размера исходной выборки.



ПРОБЛЕМЫ АНАЛИЗА НПЭЭ ПО БАЛАНСОВОМУ СЧЕТЧИКУ И СЧЕТЧИКАМ СОСЕДЕЙ



- Профили электропотребления разнородных потребителей в общем случае обладают крайне низкой парной корреляцией;
- На фоне погрешности средств учета электроэнергии изменение электропотребления подозрительного потребителя может не обладать явной связью с изменением показаний балансового счетчика;
- На фоне активного роста или снижения электропотребления изменение электропотребления подозрительного потребителя может не обладать явной связью с изменением показаний балансового счетчика.

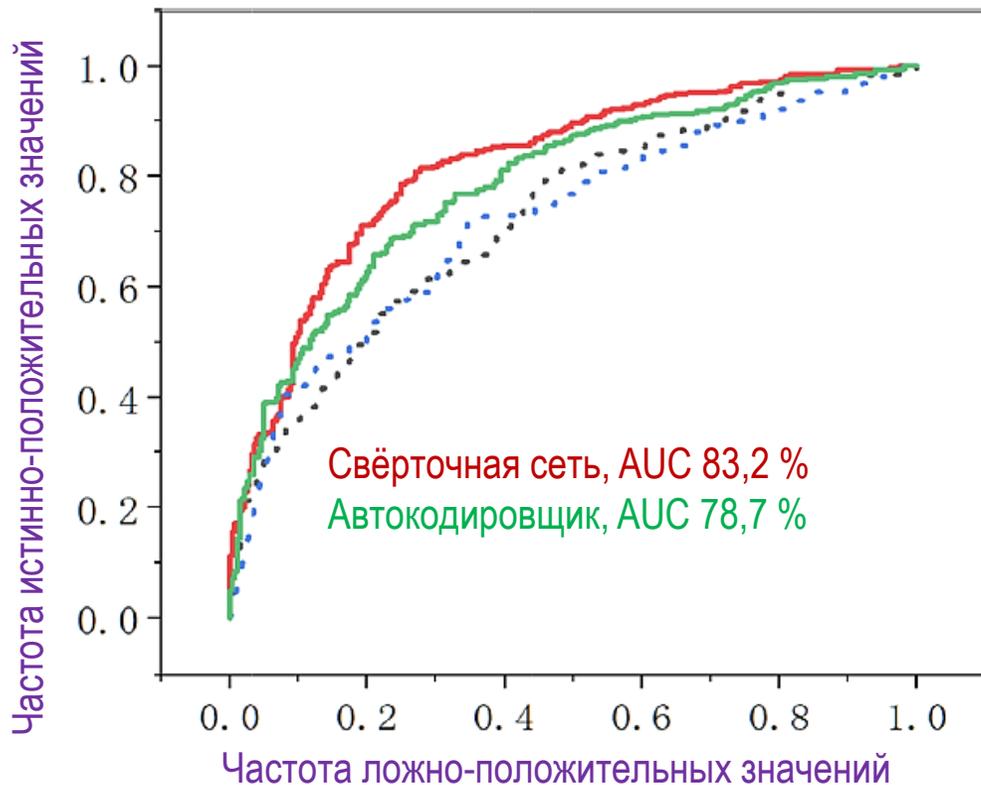


$$\gamma_n = |PearsonCorr(L, S_n)| \quad \delta_n = \left| \frac{PearsonCorr(M', S_n)}{PearsonCorr(L, S_n)} \right|$$

**Затруднено разделение
честных и нечестных
потребителей по каким-либо
пороговым значениям из
области линейной корреляции**



ЧТО ЛУЧШЕ: АВТОКОДИРОВЩИК ИЛИ СВЕРТОЧНАЯ НЕЙРОННАЯ СЕТЬ?



ИНС	Время обучения, с	Время распознавания, с
CNN + GRU	1611,10	2,49
Автокодировщик	303,42	2,37
DNN	42,04	2,35
CNN	38,81	2,13

Источник: [Electricity frauds detection in Low-voltage networks with contrastive predictive coding]

- Автокодировщик в большинстве публикаций незначительно уступает по эффективности гибридным моделям на основе сверточной нейронной сети + сети памяти (GRU, LSTM, ...), отставание по чувствительности в пределах 3 %, по специфичности в пределах 1 %;
- Автокодировщик с большим количеством слоев обучается несколько медленнее, чем простые сети прямого распространения или сверточные, но намного быстрее, чем гибридные модели на основе нескольких видов ИНС;
- Время распознавания НПЭЭ у всех видов ИНС примерно одинаково;
- Автокодировщик менее чувствителен к исходным данным и проще в понимании и настройке.



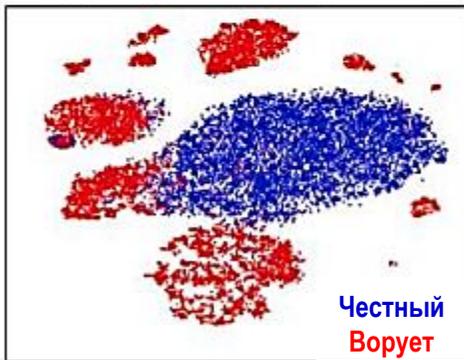
2D-ГРАФИЧЕСКАЯ ИНТЕРПРЕТАЦИЯ РАБОТЫ АВТОКОДИРОВЩИКА



Исходные данные



Метод главных компонент



Автокодировщик 1



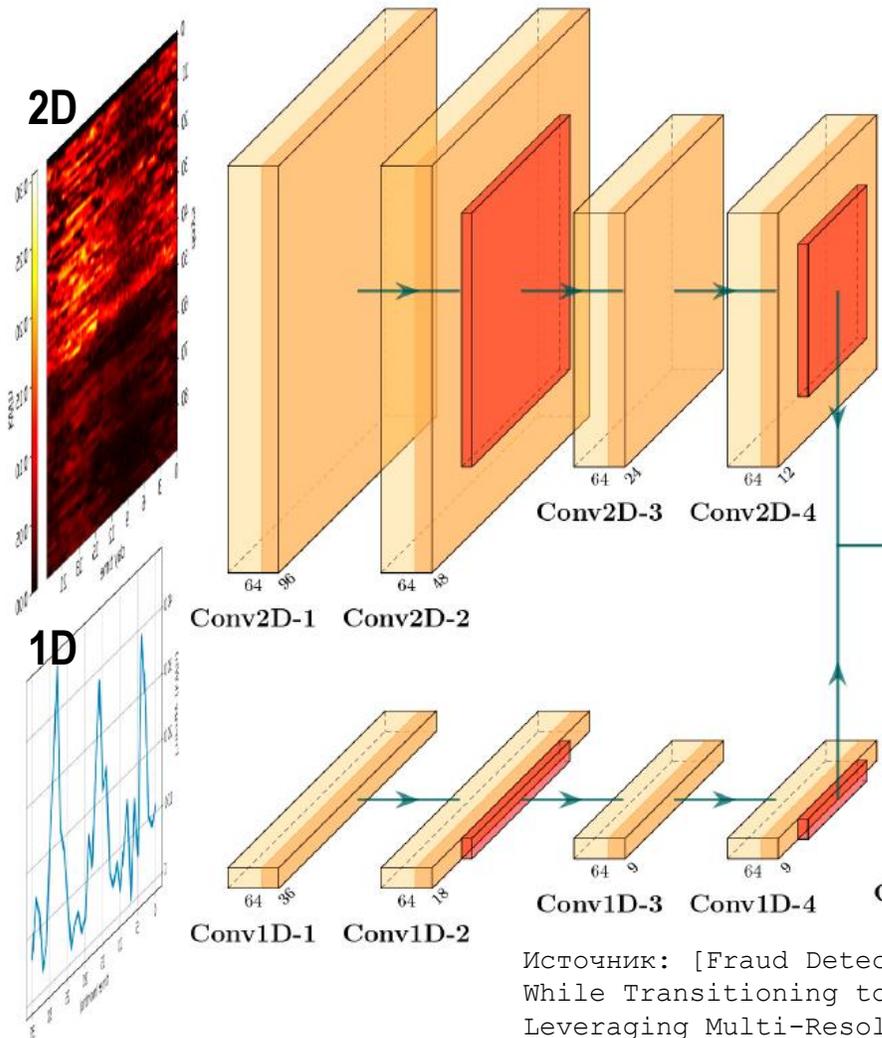
Автокодировщик 2

Сравнение:

- исходная выборка в координатах «потребитель» – «электропотребление»;
- метод принципиальных компонент с понижением размерности количества потребителей со 168 до 2 «типовых» потребителей;
- выборка в собственных координатах простого автокодировщика с тремя скрытыми слоями;
- выборка в собственных координатах стекового автокодировщика с тремя скрытыми слоями.

- Применение автокодировщика позволяет выявить характерные особенности электропотребления различных потребителей, уменьшить шум (эквивалентно уменьшению «размерности») с сохранением вариации параметров;
- Тем самым, применение автокодировщика позволяет почти разделить точки в профиле электропотребления с возможностью их дальнейшей количественной (по пороговому принципу) или качественной (с помощью кластеризации) классификации

1D- И 2D-СВЕРТОЧНЫЕ НЕЙРОННЫЕ СЕТИ ДЛЯ РАСПОЗНАВАНИЯ НПЭЭ

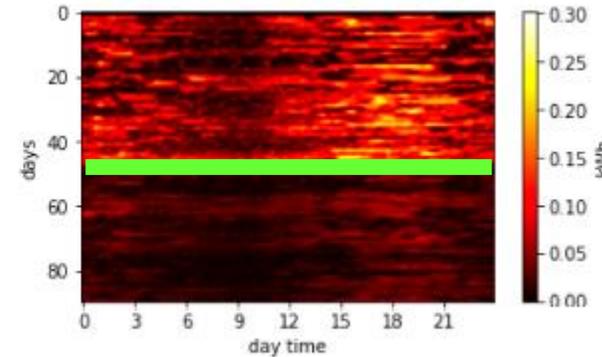
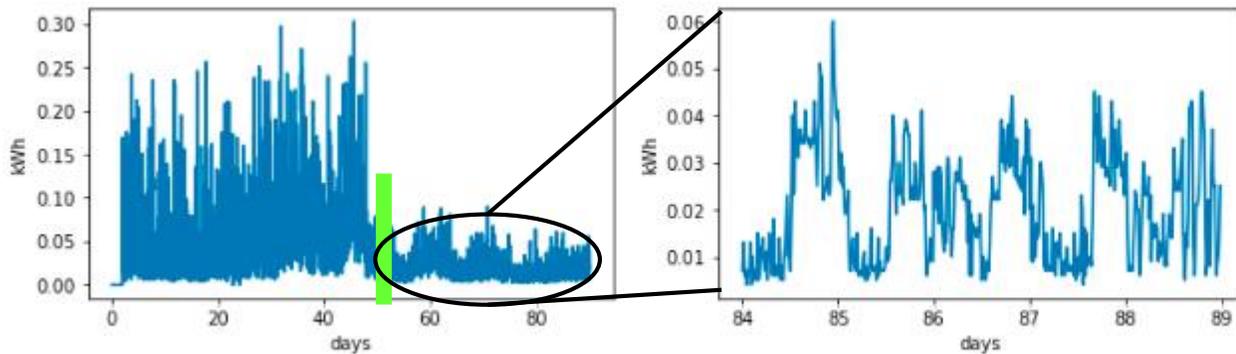


- Сверточные нейронные сети используются в теории распознавания образов для поиска локальных особенностей на изображениях;
- Применительно к поиску НПЭЭ используются одномерные и/или двумерные сверточные нейронные сети:
 1. Одномерные сверточные нейронные сети используются тогда, когда разрешение исходных данных небольшое. В частности, это может быть значение электропотребления за сутки в течение месяца. Тогда разрешение вектора входных данных (изображения) составит $31 \times W_{\text{сут}}$;
 2. Двухмерные сверточные нейронные сети используются для анализа высокодискретных значений. Например, это может быть значение электропотребления за час в сутках в течение месяца. Тогда разрешение вектора входных данных (изображения) составит $31 \times 24 \times (W_{\text{час}})$.

Источник: [Fraud Detection on Power Grids While Transitioning to Smart Meters by Leveraging Multi-Resolution Consumption Data]

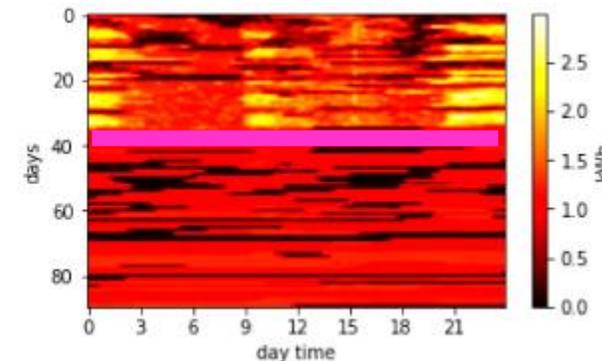
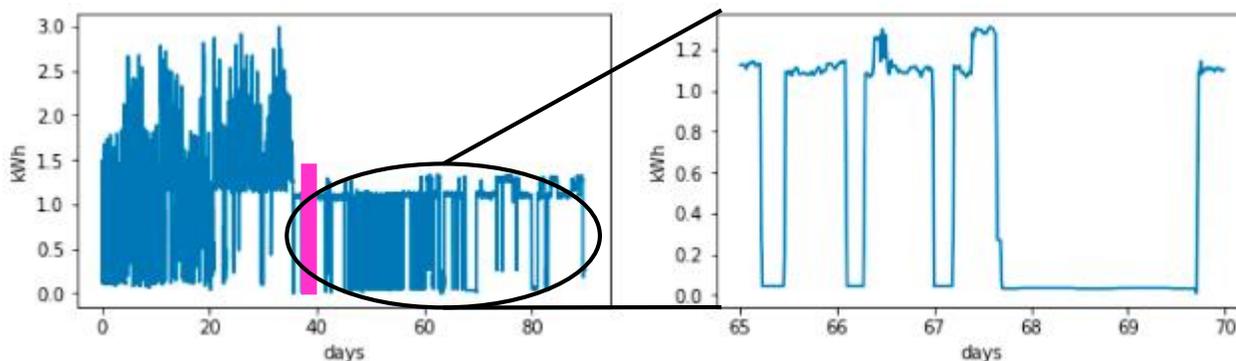
2D-ГРАФИЧЕСКАЯ ИНТЕРПРЕТАЦИЯ РАБОТЫ СВЕРТОЧНОЙ НЕЙРОННОЙ СЕТИ

НПЭЭ вследствие снижения электропотребления на определенную величину



«Расслоение» изображения по насыщенности цвета: половина значений обладает высокой насыщенностью, половина - низкой

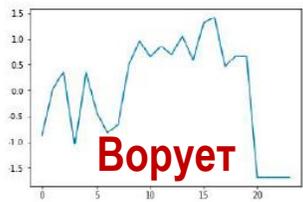
НПЭЭ вследствие исчезновения пиков электропотребления (электропотребление в обход счетчика)



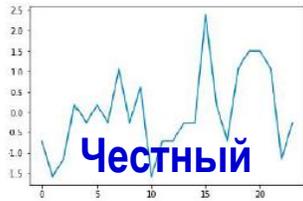
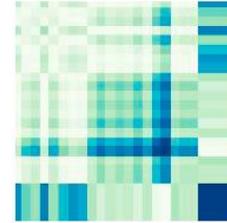
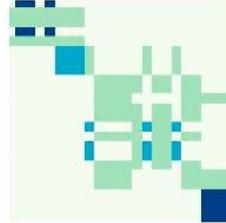
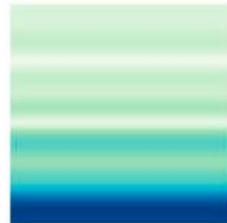
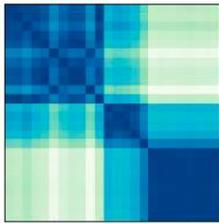
«Расслоение» изображения по наличию полос: 1/3 изображения содержит полосы с высокой насыщенностью цвета, 2/3 – не содержит таких полос

ВАРИАНТЫ ИНОГО ПРЕДСТАВЛЕНИЯ ИЗОБРАЖЕНИЯ ДЛЯ 2D-СВЕРТОЧНЫХ ИНС

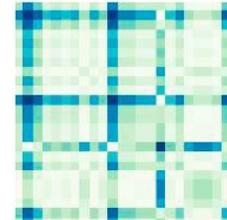
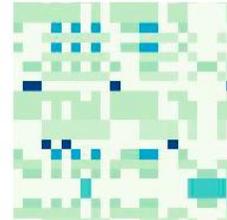
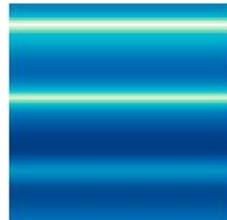
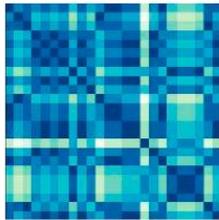
Примеры графического представления результатов свёртки



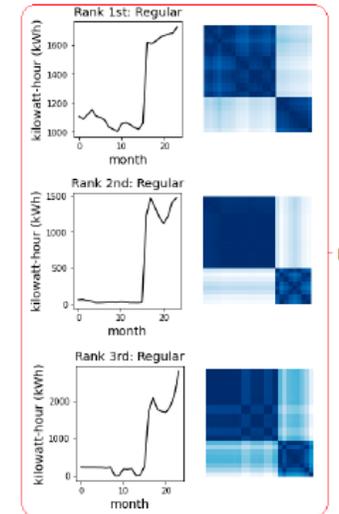
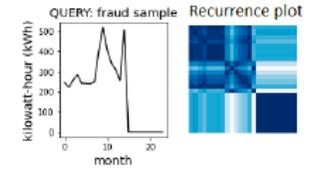
Fraud



Non-fraud



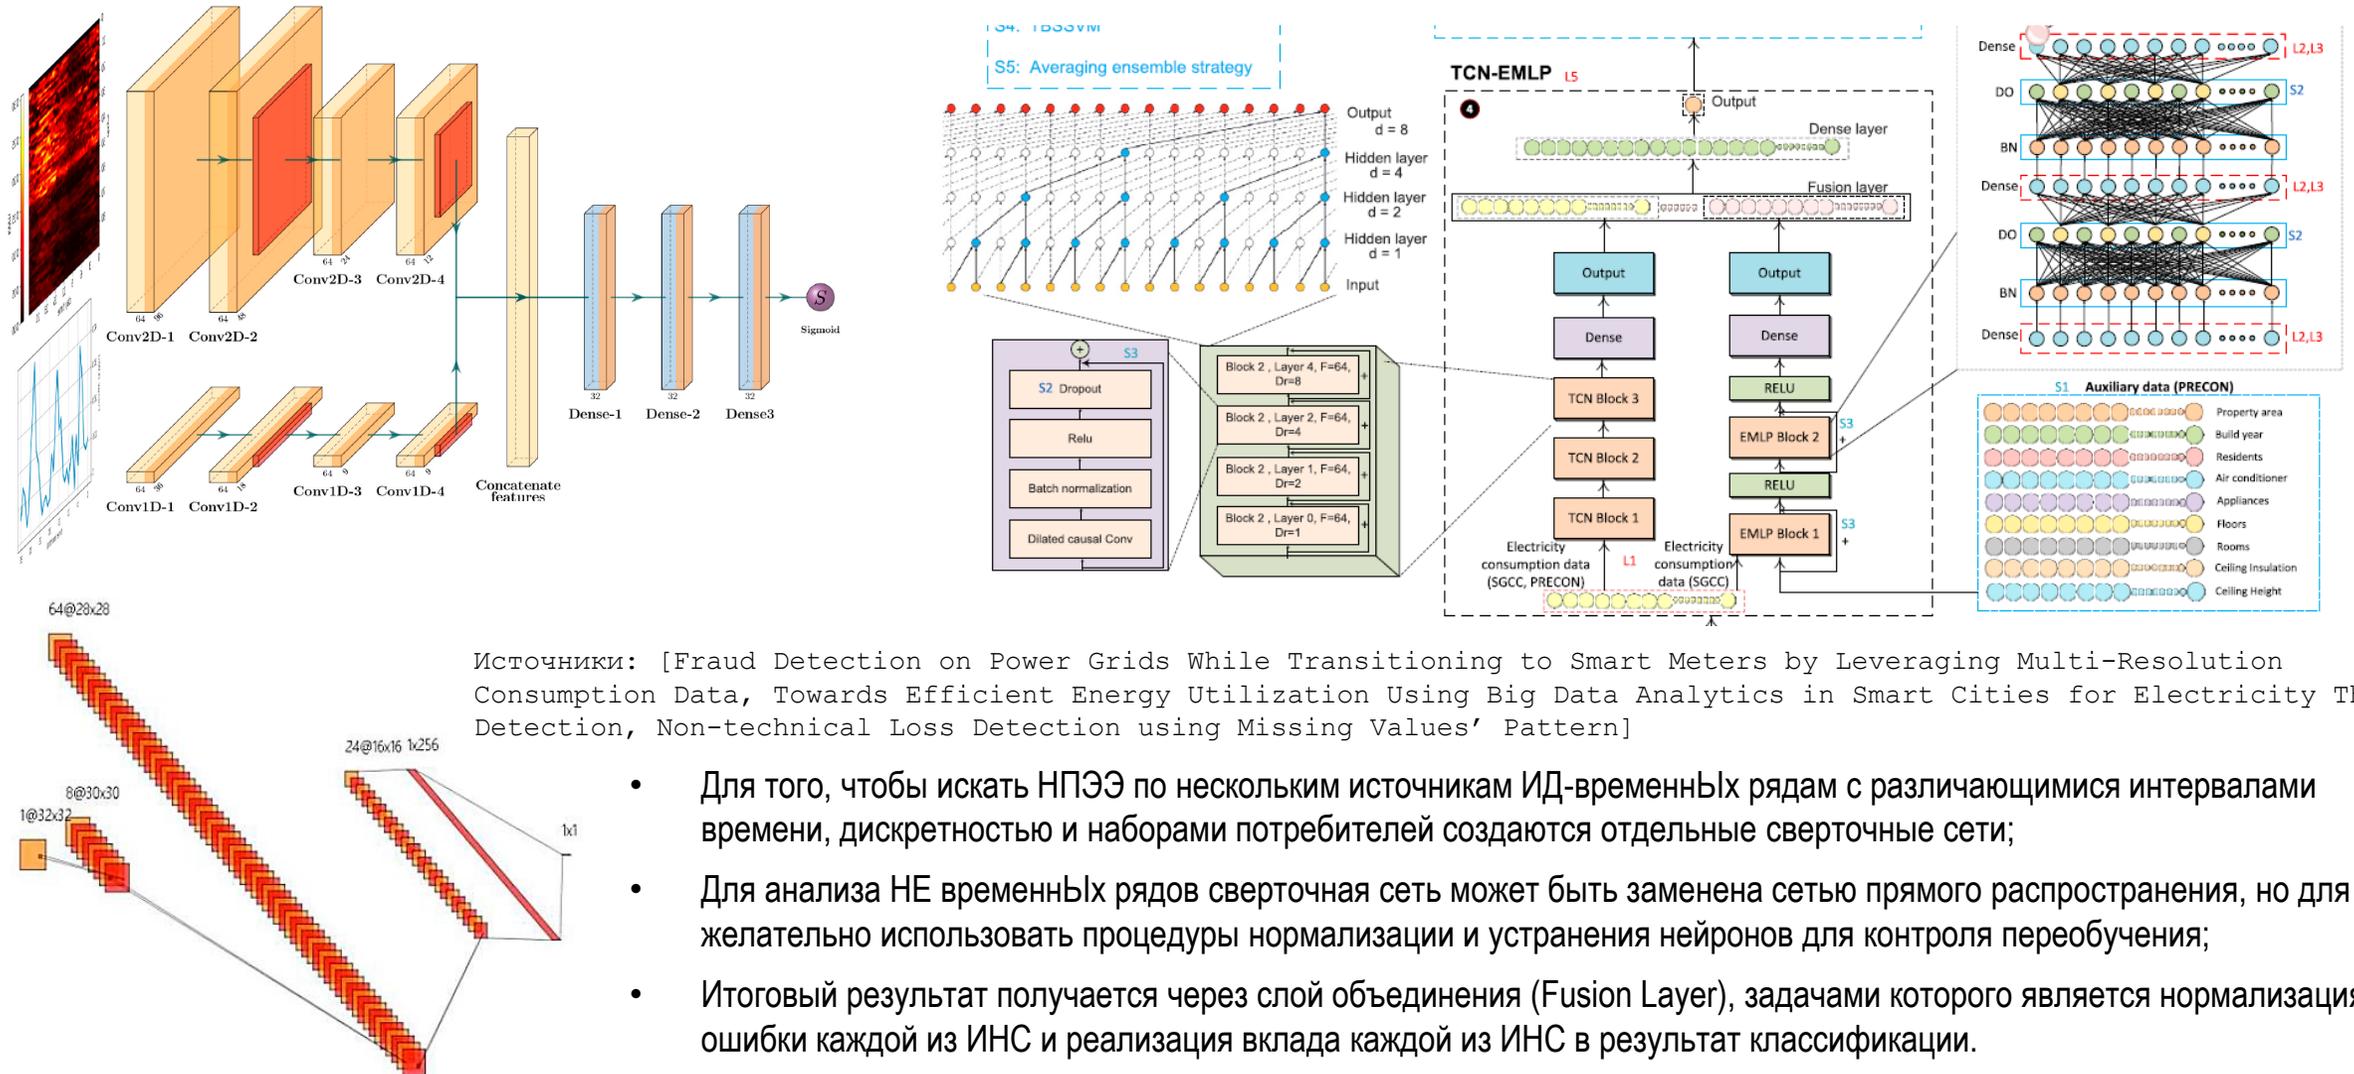
Источник: [Non-Technical Loss Detection in Power Grid Using Information Retrieval Approaches: A Comparative Study]



Failure type: #1

- В теориях нелинейной динамики, распознавания образов, обработки сигналов и обработки изображений показано, что эффективность анализа изображений, в т.ч. с помощью ИНС, можно повысить за счет специального представления сигнала (траектории, профиля);
- К наиболее широко используемым вариантам относятся спектрограммы, рекуррентные диаграммы и потенциальные поля;
- Достоинством такого представления является появление низкоконтрастных частей изображения = длительных нестационарных процессов (НПЭЭ);
- Существенным недостатком является ненаправленность изображения, что может приводить к ложно-положительным срабатываниям алгоритма при росте нагрузки (см. рисунок в правой части слайда)

МНОЖЕСТВЕННЫЕ ИНС ДЛЯ РАСПОЗНАВАНИЯ НПЭЭ

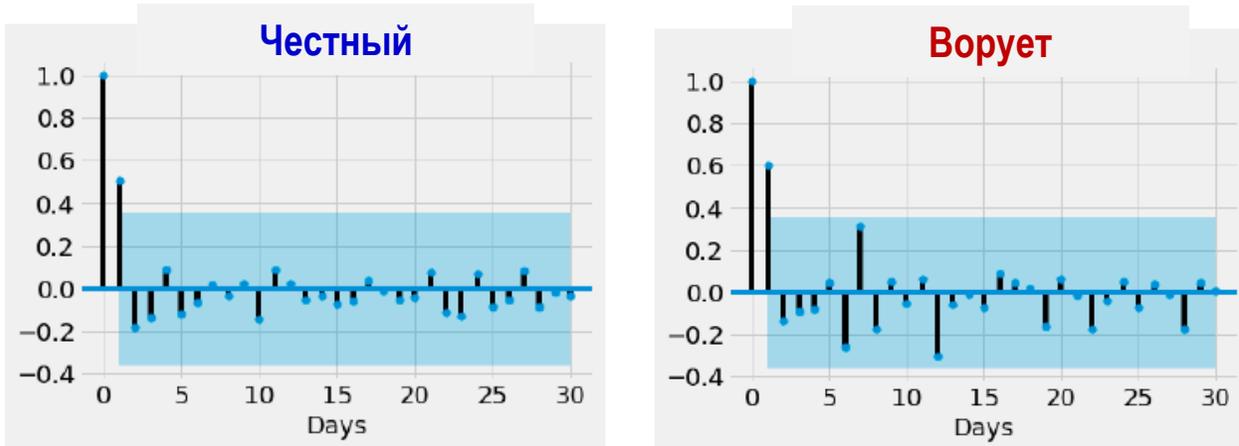


Источники: [Fraud Detection on Power Grids While Transitioning to Smart Meters by Leveraging Multi-Resolution Consumption Data, Towards Efficient Energy Utilization Using Big Data Analytics in Smart Cities for Electricity Theft Detection, Non-technical Loss Detection using Missing Values' Pattern]

- Для того, чтобы искать НПЭЭ по нескольким источникам ИД-временных рядов с различающимися интервалами времени, дискретностью и наборами потребителей создаются отдельные сверточные сети;
- Для анализа НЕ временных рядов сверточная сеть может быть заменена сетью прямого распространения, но для нее желательно использовать процедуры нормализации и устранения нейронов для контроля переобучения;
- Итоговый результат получается через слой объединения (Fusion Layer), задачами которого является нормализация ошибки каждой из ИНС и реализация вклада каждой из ИНС в результат классификации.

ГИБРИДНЫЕ ИНС С ЭЛЕМЕНТАМИ «ПАМЯТИ»

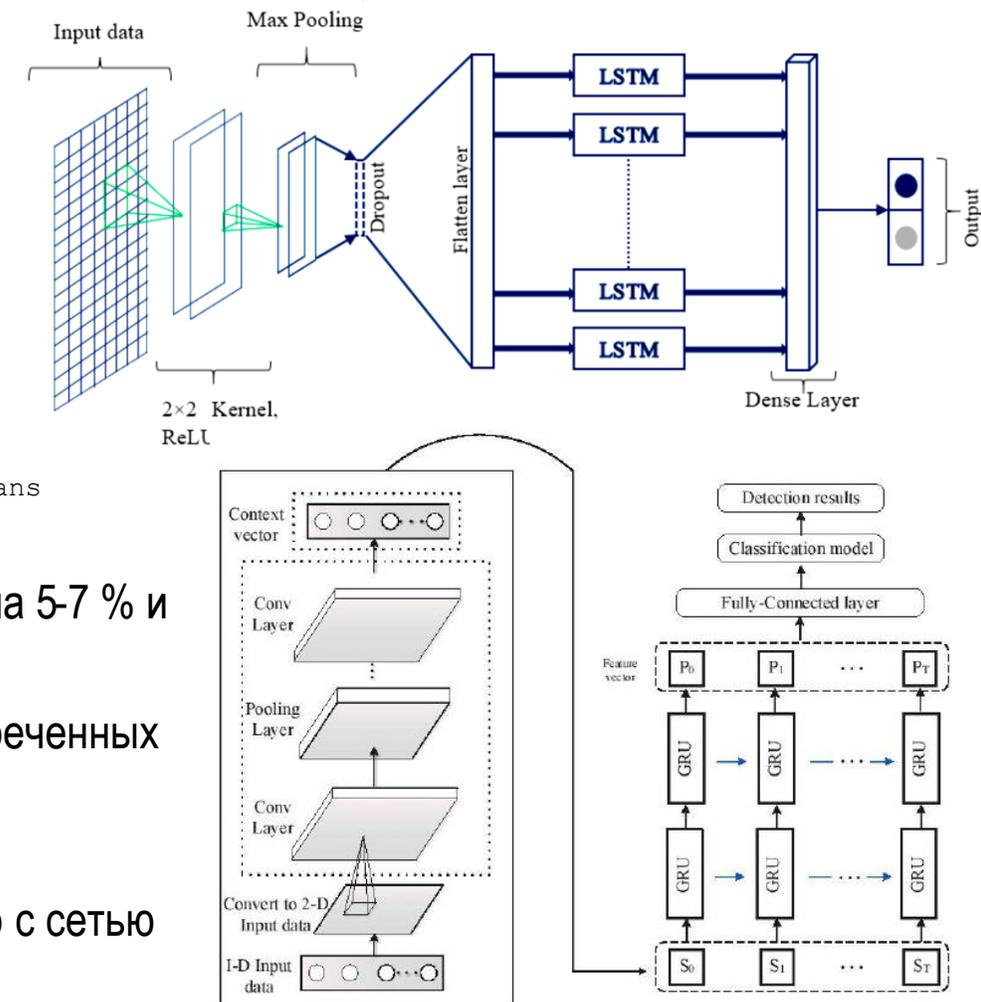
Автокорреляция профиля с подозрительными измерениями



Источники: [A Data-Driven Method for Electricity Theft Detection Combining ConvGRU and K-means Clustering, Electricity Theft Detection in Smart Grid Systems: A CNN-LSTM Based Approach]

- Рекуррентные сети и сети памяти повышают чувствительность алгоритма на 5-7 % и снижают частоту ложно-положительных значений на 3-5%;
- Принцип работы основан не столько на запоминании отдельных ранее встреченных аномалий графика, сколько на установлении авторегрессионной связи в подозрительном профиле электропотребления;
- Рекуррентные сети и сети памяти встраиваются в модель последовательно с сетью распознавания образов, обобщают зависимость и запоминают образы.

Примеры ИНС с элементами памяти





ОБЩАЯ ПОСЛЕДОВАТЕЛЬНОСТЬ ВЫЯВЛЕНИЯ НПЭЭ. СУТЬ

Подготовка и предварительная обработка данных

- Выбор типов используемых ИД
- Отсев выбросов ИД
- Замещение потерянных ИД
- МИНИМАКС нормализация ИД
- Генерация НПЭЭ в ИД без НПЭЭ (опция)
- Разметка ИД в случае, если не размечены (опция)
- Балансировка ИД по классам без/с НПЭЭ
- Синтез дополнительных данных с помощью GAN (опция)
- Разбивка ИД на обучающую, проверочную и тестовую выборки

Работа ИНС

- Выбор ИНС для работы с выбранными типами ИД
- Обучение ИНС и оптимизация гиперпараметров
- Контроль переобучения ИНС на проверочной выборке
- Тест ИНС на тестовой выборке
- Сведение результатов отдельных ИНС (если используются)
- Запрос к оператору о спорных случаях и их исключение (опция)

Вывод результата

- Расчет показателей эффективности классификации
- Вывод информации о НПЭЭ в графическом и табличном виде



РАЗНИЦА В ПОДХОДАХ ВЫЯВЛЕНИЯ НПЭЭ ВЛИЯЕТ В ДАЛЬНЕЙШЕМ НА НАСТРОЙКУ ИНС

Подход

Поиск НПЭЭ по подозрительному участку профиля

Поиск НПЭЭ по подозрительному потребителю

Достоинства

Анализируется профиль конкретного потребителя, снижается частота ложно-положительных значений

Высокая чувствительность к аномалиям электропотребления на общем фоне

Квадратная матрица на входе и общераспространенные настройки свертки, сбережение вычислительных ресурсов

Может выявлять условно-постоянные и неразмеченные НПЭЭ

Понятен источник НПЭЭ

Понятно время факта НПЭЭ

Недостатки

Не обнаруживает условно-постоянные и неразмеченные НПЭЭ

Соседи как источники референсных значений могут отсутствовать

Сложно установить точное время НПЭЭ (когда-то тогда)

Сложно установить конкретный источник НПЭЭ (где-то здесь)

Вывод

Эффективнее всего совместное применение подходов в модульном алгоритме.



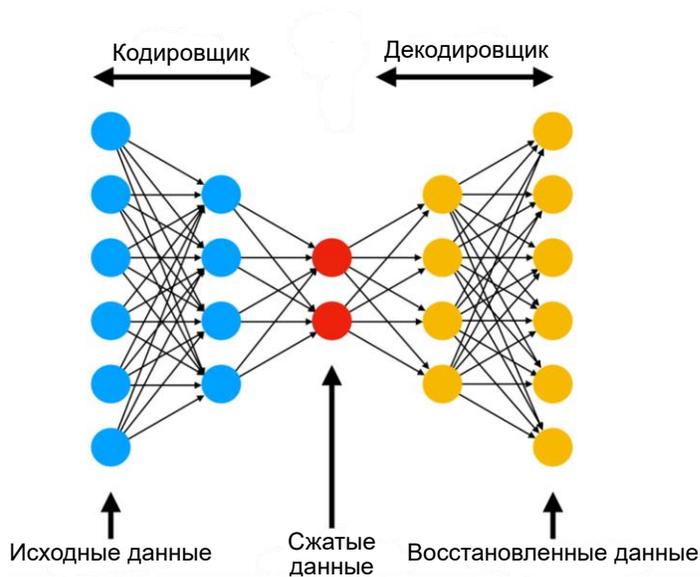
ТЕСТОВЫЕ РАСЧЁТЫ ПО РЕЗУЛЬТАТАМ ОТБОРА ЛУЧШИХ ПРАКТИК



ОПИСАНИЕ ВЫЧИСЛИТЕЛЬНОГО ЭКСПЕРИМЕНТА

Набор данных	Low Carbon London dataset
Количество точек исходной выборки	200 млн.
Дискретность исходной выборки	30 мин.
Выбор типов используемых ИД	Величины (профили) потребления электроэнергии
Отсев выбросов ИД	3σ
Замещение потерянных ИД	Исключение
МИНИМАКС нормализация ИД	Да
Генерация НПЭЭ в ИД без НПЭЭ	Да
Разметка ИД в случае, если не размечены	Нет
Балансировка ИД по классам без/с НПЭЭ	Нет
Синтез дополнительных данных с помощью GAN	Нет
Разбивка ИД на обучающую, проверочную и тестовую выборки	60-20-20 %
Контроль переобучения ИНС на проверочной выборке, тест ИНС на тестовой выборке	Да
Выбор ИНС для работы с выбранными типами ИД	Автокодировщик, Свёрточная
Обучение ИНС и выбор гиперпараметров	См. следующий слайд
Метрика	Площадь под кривой частот истинно-положительных и ложно-положительных результатов (AUC ROC)

ИСКУССТВЕННАЯ НЕЙРОННАЯ СЕТЬ – АВТОКОДИРОВЩИК



Типы тестируемых автокодировщиков:

1. Автокодировщики с полносвязными слоями на суточный график
2. Свёрточный автокодировщик
 - А. Плоские одноканальные на суточный и недельный графики
 - В. Многоканальный на недельный график
 - а) Со среднеквадратической функцией ошибки
 - б) С логарифмической функцией ошибки

Параметры тестируемых свёрточных автокодировщиков

Многомерность (количество входных каналов)	1D – Суточные интервалы; 2D – Суточные по дням недели интервалы
Размерность входного слоя	48; 336; 48x7
Количество сверточных слоев	3; 13; 6
Размерность ядра фильтра	5x1
Количество фильтров	2-8; 2-32; 14-32
Количество слоев субдискретизации	0; 5; 0
Шаг	1, в слоях субдискретизации 2
Количество скрытых полносвязных слоёв	0; 0; 3
Количество нейронов	64-512
Количество эпох обучения	10; 30; 30
Функция активации	ReLU, Sigmoid (выходной слой)
Алгоритм обучения	Adam
Скорость обучения	10 ⁻⁴



ПРИМЕРЫ РАБОТЫ ОБУЧЕННОГО АВТОКОДИРОВЩИКА С ПОЛНОСВЯЗНЫМИ СЛОЯМИ

Обученный автокодировщик с размерами слоёв
48-32-24-16-8-4-8-16-24-32-48

Обученный автокодировщик с размерами слоёв
48-32-24-16-8-16-24-32-48



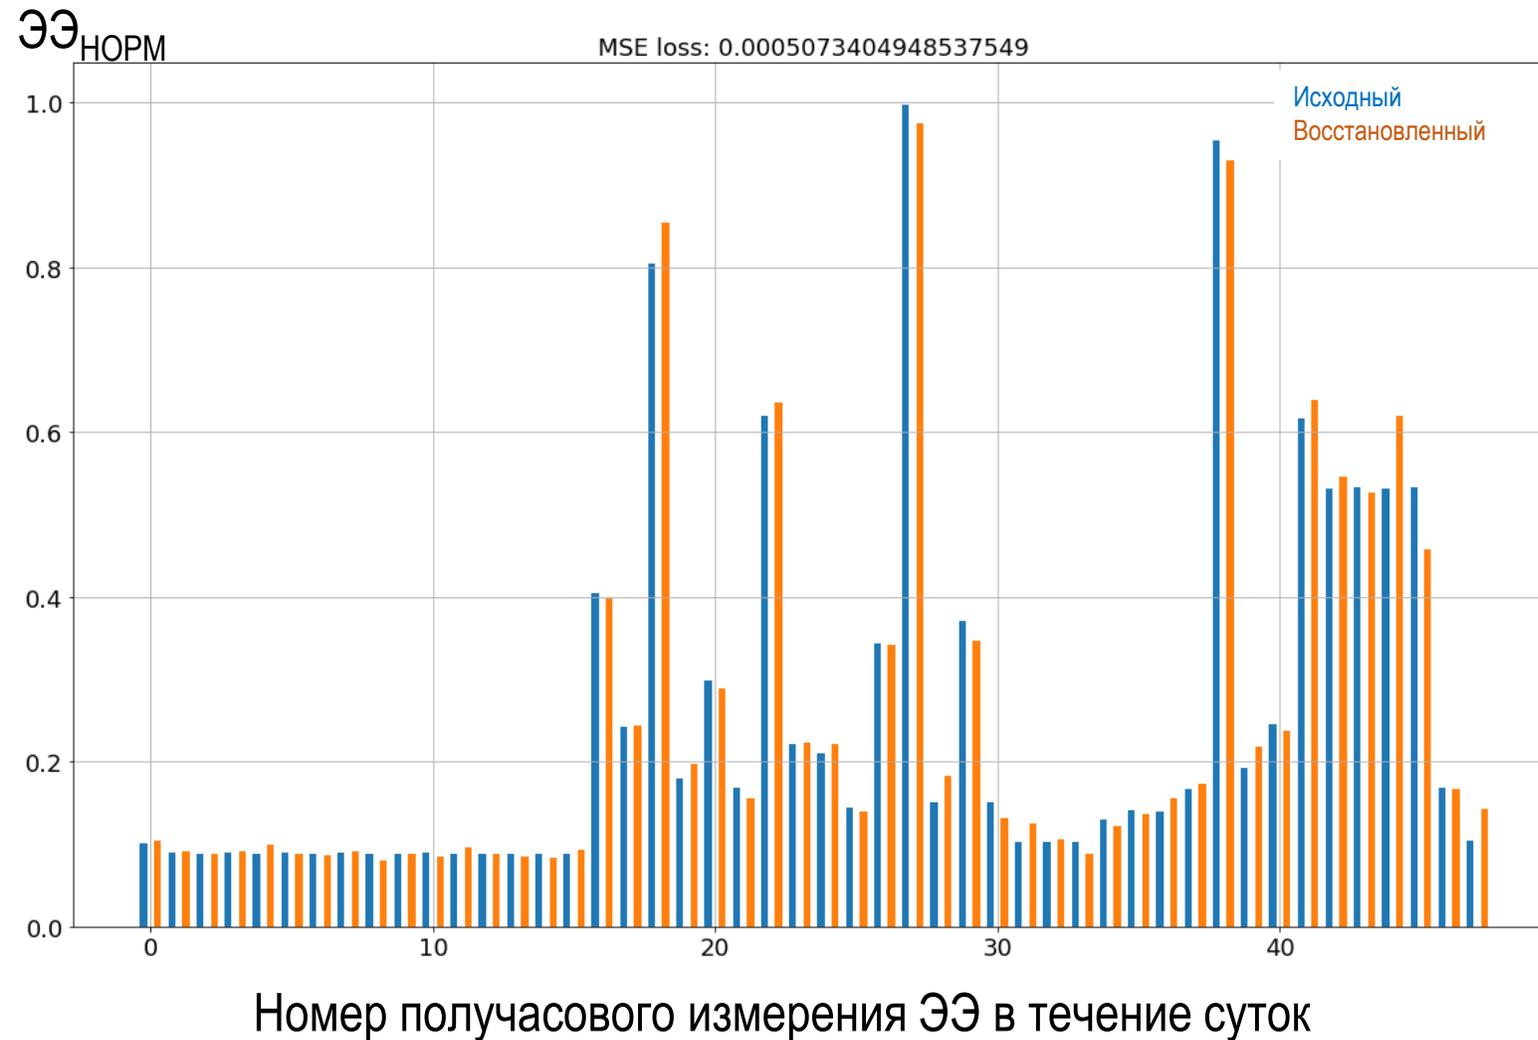
Номер получасового измерения ЭЭ в течение суток



Номер получасового измерения ЭЭ в течение суток



ПРИМЕР РАБОТЫ ОБУЧЕННОГО СВЁРТОЧНОГО АВТОКОДИРОВЩИКА

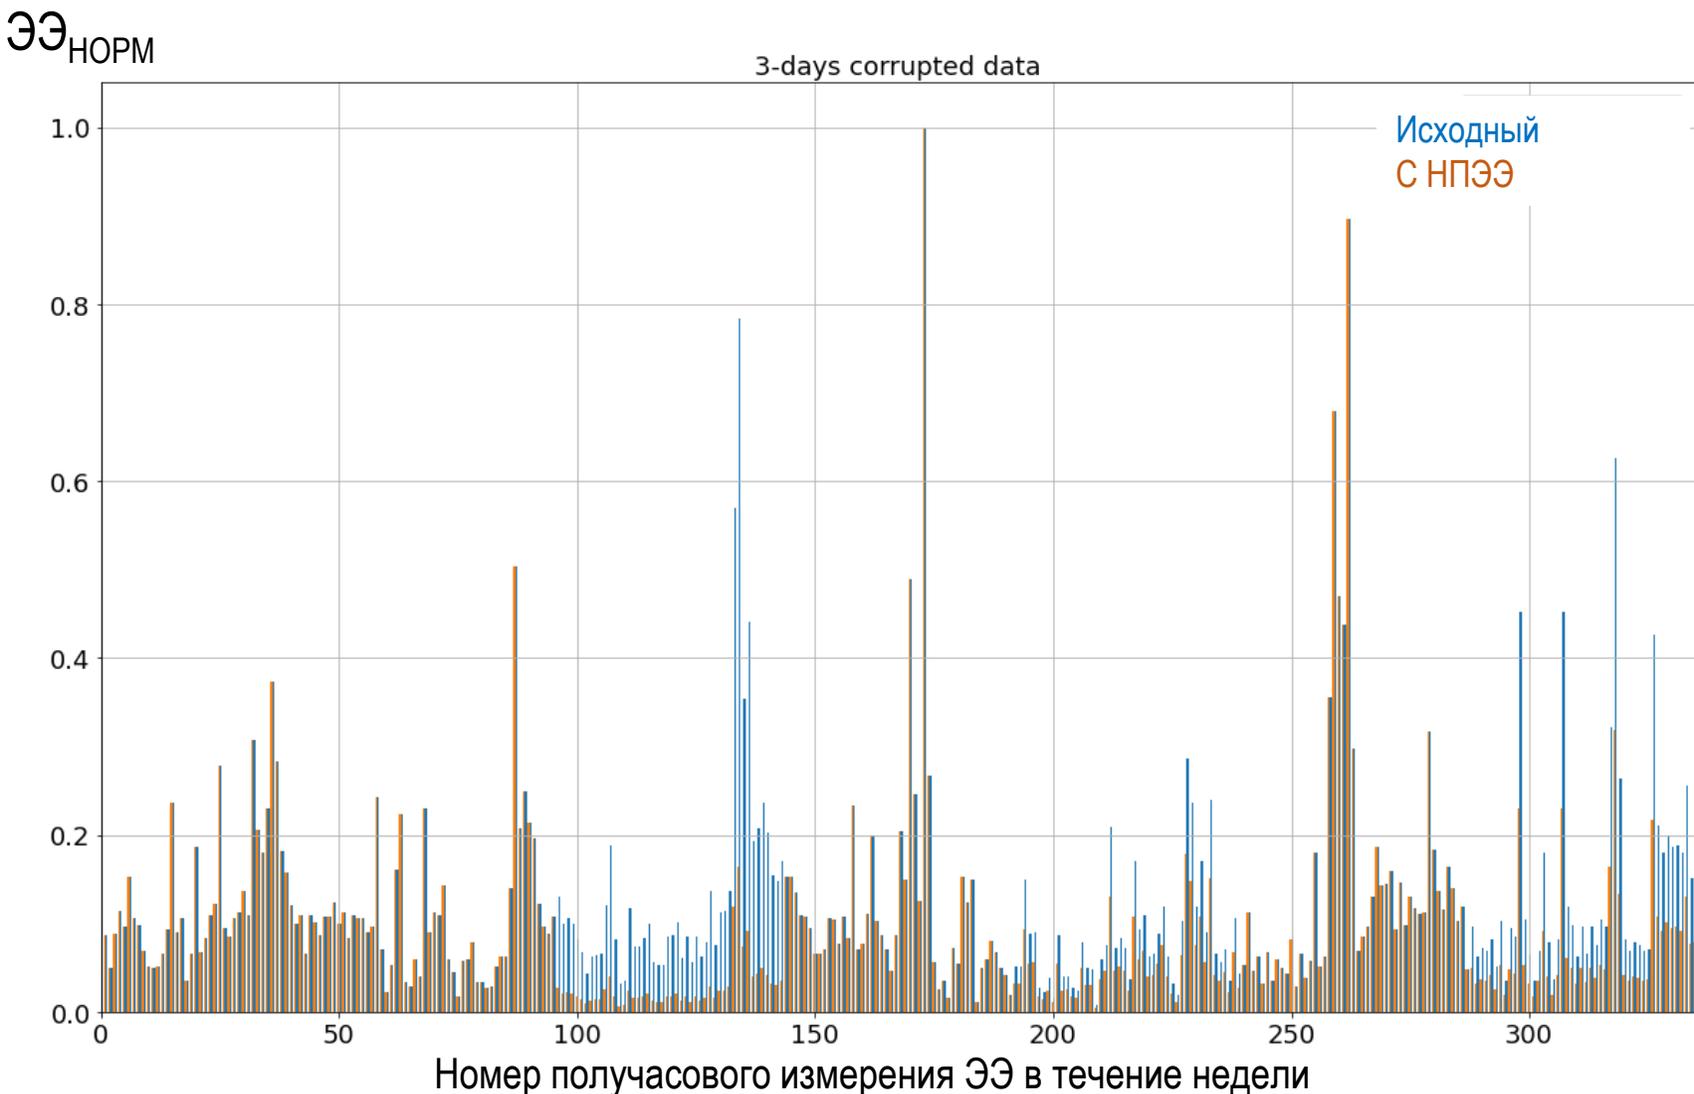


№	Автокодировщик для суточного интервала	Среднеквадрати- ческая ошибка
1	С полносвязными слоями 48-32-24-16-8-4- 8-16-24-32-48	$23,5 \cdot 10^{-3}$
2	С полносвязными слоями 48-32-24-16-8-16- 24-32-48	$20,0 \cdot 10^{-3}$
3	Свёрточный автокодировщик	$0,5 \cdot 10^{-3}$

Результат лучше на 1,5-2 порядка



ПРИМЕР ВНЕСЕНИЯ ИСКАЖЕНИЙ В 30 МИН-ЗНАЧЕНИЯ ЭЛЕКТРОПОТРЕБЛЕНИЯ ЗА НЕДЕЛЮ



Реалистичные модели НПЭЭ:

1. Каждые 48 получасовок подряд (полные сутки) умножаются на случайный коэффициент 0,1-0,8;
2. Каждая из получасовок умножается на случайный коэффициент 0,1-0,8;
3. Вычисляется среднее значение потребления за неделю. Каждой из получасовок присваивается значение, равное произведению среднего на случайный коэффициент 0,1-0,8.

Типы искажения графиков:

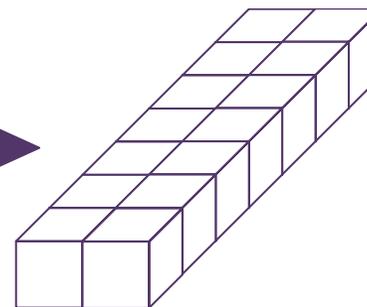
1. Слабое – в сумме ~3 суток;
2. Среднее – в сумме ~5 суток;
3. Сильное – в сумме ~7 суток.



ИСПОЛЬЗОВАНИЕ СВЁРТОЧНЫХ ПЛОСКОГО И МНОГОКАНАЛЬНОГО АВТОКОДИРОВЩИКОВ

Каждый день – отдельный канал

Все дни идут друг за другом

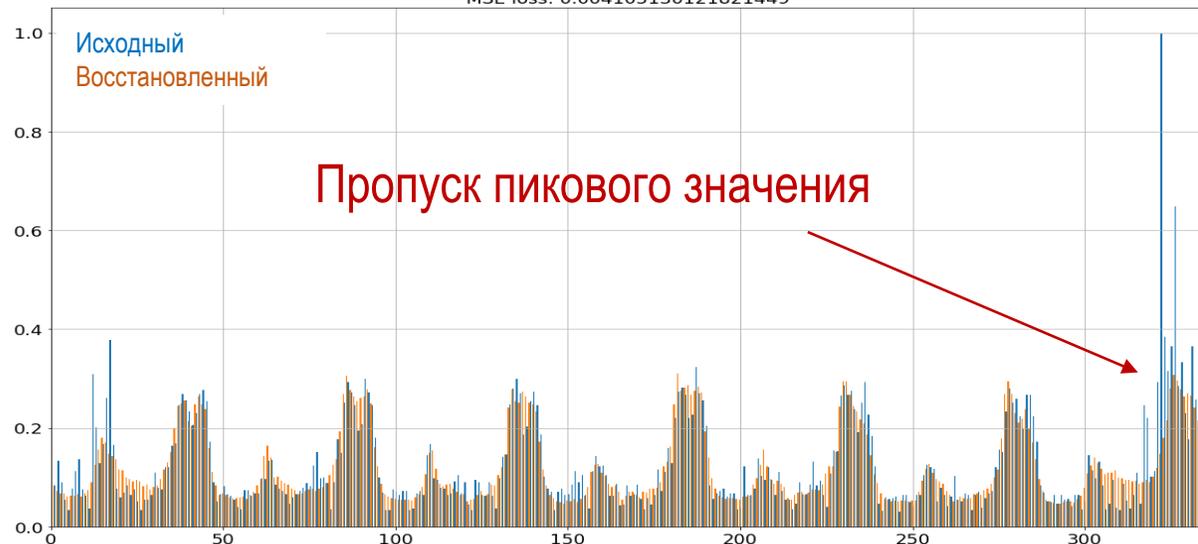


[1 x 336]

[7 x 48]

ЭЭ_{НОРМ}

MSE loss: 0.004105130121821449



MSE loss: 0.0019742892611594428





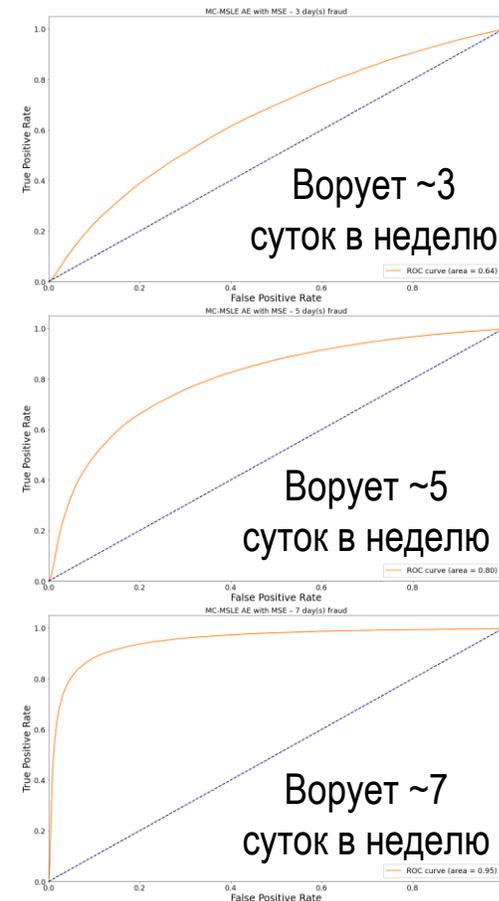
ИСПОЛЬЗОВАНИЕ СВЁРТОЧНОГО МНОГОКАНАЛЬНОГО АВТОКОДИРОВЩИКА С ЛОГАРИФМИЧЕСКОЙ ФУНКЦИЕЙ ОШИБКИ (MSLE)

ЭЭ_{НОРМ}

MSE loss: 0.0017370533730302537



Частота истинно-положительных значений



Частота ложно-положительных значений

СРАВНЕНИЕ ЭФФЕКТИВНОСТИ СВЁРТОЧНЫХ АВТОКОДИРОВЩИКОВ

Критерии отнесения графика к графику, содержащему НПЭЭ:

1. В модельных данных – 90-й перцентиль по среднеквадратическому отклонению **восстановленных** графиков от **исходного**;
2. В реальных данных – правее точки перегиба (максимум второй производной) ранжированной кривой среднеквадратического отклонения.



№	Автокодировщик	Доля площади под кривой частот истинно-положительных и ложно-положительных значений (ROC AUC)			Время обучения
		При слабом искажении Ворует ~3 суток	При среднем искажении Ворует ~5 суток	При сильном искажении Ворует ~7 суток	
1	Плоский автокодировщик	62 %	77 %	95 %	3,5 часа
2	Многоканальный автокодировщик	63 %	79 %	94 %	2,5 часа
3	Многоканальный автокодировщик (логарифмич. ф-ция ошибки)	64 %	80 %	95 %	2,5 часа



ВЫВОДЫ

1. Искусственные нейронные сети для выявления НПЭЭ используются в 41 % публикаций по методам выявления НПЭЭ, в т.ч. в 24 % сверточные нейронные сети и в 9 % автокодировщики;
2. В среднем ИНС обеспечивают достоверность выявления *модельных* НПЭЭ на уровне 92 %, лучшие – на уровне 95-97 %;
3. В 76 % публикаций используются только профили электропотребления без привлечения дополнительных исходных данных. Вспомогательными данными являются электрические параметры, метеоданные и, реже, кадастровые данные и геолокация;
4. Глубина ретроспективы 30-минутных профилей электропотребления должна составлять не менее 1 года, желательно 2+ года и несколько сотен потребителей;
5. Все основные виды НПЭЭ, в т.ч. сбои систем учета и хищения, можно смоделировать 6-ю типами искажений профиля ЭЭ;
6. В научных публикациях тестирование ИНС производится на архивных наборах данных из открытых источников. Ученым и инженерам в России нужен подобный набор данных!
7. Для достижения результата крайне важна подготовка данных в виде восстановления пропусков, фильтрации, нормализации и, в случаях дефицита значений из наименьшего класса, балансировки выборки;
8. При проведении вычислительного эксперимента и тестовых расчетов достигнута эффективность выявления НПЭЭ на модельных данных, сопоставимая с лучшими результатами в мировых публикациях.



Кафедра

Автоматизированные
Электрические Системы



Уральский
федеральный
университет

имени первого Президента
России Б. Н. Ельцина

Уральский
энергетический
институт

БЛАГОДАРЮ ЗА ВНИМАНИЕ!

Докладчик:

В. О. Самойленко

v.o.samoylenko@urfu.ru

Екатеринбург, 2023