

Федеральное государственное автономное образовательное учреждение
высшего образования
«Национальный исследовательский университет
«Высшая школа экономики»

На правах рукописи

Чертенков Владислав Игоревич

**Исследование универсальности моделей статистической механики
методами машинного обучения**

РЕЗЮМЕ ДИССЕРТАЦИИ

на соискание ученой степени кандидата наук по прикладной математике

Научный руководитель:
доктор физико-математических наук
профессор Щур Лев Николаевич

Москва – 2024

Актуальность исследования

Внедрение методов машинного обучения (МО) для исследования фазовых переходов является перспективным направлением. Алгоритмы МО позволяют решать задачи с большим объемом данных. Нейронные сети (НС) широко применяются в задачах анализа естественного языка, визуального распознавания объектов, прогнозирования временных рядов и инженерных приложениях. Для решения проблем в различных доменных областях, алгоритмам не требуется априорное понимание природы данных, а только достаточное количество примеров для обучения. Например, для понимания естественного языка, нейронной сети не нужно знать принципы морфологии и семантики языка.

Анализ количества научных публикаций с 2015 по 2023 год, по данным Google Scholar, показывает рост интереса к инструментам МО в физике конденсированного состояния. Использование машинного обучения для исследования фазовых переходов позволит объединить классические методы статистической физики и передовые подходы к моделированию сложных процессов. Междисциплинарный подход позволит обогатить текущую теоретическую базу новыми методами для более глубокого понимания сложной динамики фазовых переходов и интерпретации физических систем.

Помимо теоретического значения, практическая ценность заключается в появлении новых инструментов, программных комплексов и методов для работы с фазовыми переходами в реальных системах. А распространение методов МО откроет возможности для создания приложений в материаловедении, физике высоких энергий и других смежных областях.

Степень разработанности темы

В работе [1] предложен подход к анализу фазовых переходов методом обучения с учителем. Решая задачу классификации фаз для модели Изинга на квадратной решетке, численно извлечена критическая температура $T_c^* = 2.266(2)$ и критический показатель $\nu = 1.0(2)$ через коллапс выходных данных НС. Переносом знания получена оценка $T_c^* = 3.65(1)$ и $\nu = 1.0(3)$ для модели Изинга с треугольной топологией решетки [2]. Решая задачу регрессии для предсказания температуры спиновых конфигураций [3] осуществляется перенос знания о фазовом переходе с модели Изинга на q-компонентную модель Поттса с точностью T_c^* до 3 знака после запятой для $q \in [2; 10]$.

Для генерации новых примеров на решетке с сохранением распределения статистик термодинамических показателей [4], используют генеративно-сопоставительные сети (GAN). Решением задачи понижения размерности обучения без учителя [5], извлекается критическая температура $T_c^* = 2.266(4)$ в модели Изинга. Методами МО исследуют [6–9] фазовый переход в задачах перколяции и БКТ-переход в XY-и q-компонентной часовой модели.

При сравнении точности методов извлечения величин W , вводится понятие относительной погрешности метода ϵ , % (формула 1). Например, если численная оценка критической температуры $\hat{T}_c = 2.258(5)$ для точного решения $T_c = 2.269$, то $\epsilon = 100 \cdot \max(|2.269 - 2.258|, 0.005)/2.269 = 100 \cdot \max(0.011, 0.005)/2.269 = 0.5\%$.

$$\epsilon = 100 \cdot \max(|W - \hat{W}|, W_e)/W. \quad (1)$$

Численное извлечение критической температуры T_c^* с помощью методов МО неоднократно подтверждается в разных статьях. Относительная погрешность T_c^* (далее погрешность, см. выражение 1) в большинстве работ составляет менее 1%. Критический показатель корреляционной длины ν извлекается менее постоянно и с большей погрешностью. Численные оценки ν в оригинальной работе [1] имеют относительную погрешность 20% для квадратной и 30% для треугольной решеток модели Изинга. Многие работы используют метод коллапса кривых, для которого численное решение ν лежит в широком диапазоне. В работе [9] применяется другой метод для извлечения критических показателей, однако независимого подтверждения полученным результатам нет.

Возникают вопросы, с какой точностью НС могут извлекать критические свойства решеточных спиновых моделей; какие факторы влияют на точность извлекаемых величин; возможно ли создать метод, который будет работать для моделей в разных классах универсальности.

Цель

Разработать метод для анализа фазовых переходов в решеточных спиновых моделях методами машинного обучения с учителем.

Задачи исследования

- Разработка метода анализа фазовых переходов в решеточных спиновых моделях методами машинного обучения с учителем с использованием нейронных сетей.
- Реализация программного комплекса для исследования фазовых переходов в решеточных спиновых моделях с помощью классических методов и нейронных сетей.
- Применение метода для исследования фазовых переходов в решеточных спиновых моделях классов универсальности Изинга и четырехкомпонентного Поттса.
- Измерение точности разработанного метода и исследование факторов, влияющих на точность.
- Разработка метода переноса знания о фазовом переходе в решеточных спиновых моделях.

Научная новизна

1. Предложен метод исследования фазовых переходов в решеточных спиновых моделях на основе масштабирования функции вариации выхода нейронной

сети, обученной решать задачу бинарной классификации с учителем. По выходным данным нейронной сети систематически извлекается оценка критической температуры и критический показатель корреляционной длины с высокой точностью.

2. Предложенным методом извлечены критические показатели корреляционной длины и критическая температура для моделей Изинга, Бакстера-Ву, Поттса ($q=4$). Для последних двух моделей критические показатели извлечены впервые методами МО.
3. Впервые исследовано влияние архитектур нейронных сетей, гиперпараметров обучения и способов предобработки входных данных на точность извлекаемых критических показателей решеточных спиновых моделей.
4. Предложен новый метод предобработки входных данных при перекрестном обучении нейронной сети с целью переноса знания о фазовом переходе между классами универсальности Изинга и четырехкомпонентной модели Поттса.

Методология и методы

Для исследования решеточных спиновых моделей классическими подходами применялись методы Монте-Карло и конечно-мерный анализ. В разработанном методе моделирования применяются методы глубокого машинного обучения, алгоритмы компьютерного зрения, нейронные сети, обучение с учителем и методы оптимизации. Общими методами исследования являются статистический анализ и численные методы аппроксимации.

Краткое содержание работы

В **первой главе** описаны исследуемые двумерные решеточные спиновые модели: Изинга [10] на квадратной решетке, модель Бакстера-Ву на треугольной решетке и четырехкомпонентная модель Поттса на квадратной решетке. В моделях наблюдается фазовый переход второго рода между ферромагнитной (упорядоченной) и парамагнитной (неупорядоченной) фазами в критической точке T_c . Существуют точные аналитические решения: модель Изинга решена Л.Онсагером [11] в 1944 году, $T_c \approx 2.269$, модель Бакстера-Ву решена Р.Бакстером и Ф.Ву [12] в 1973 году, $T_c \approx 2.269$, четырехкомпонентная модель Поттса решена Р.Поттсом [13] в 1952 году, $T_c \approx 0.91$.

Модели отличаются Гамильтонианами, топологией решеток и симметрией основного состояния. По этим признакам модели можно отнести к двум классам универсальности: Изинга, в который входит одноименная модель, и четырехкомпонентного Поттса, в который входят модели Бакстера-Ву и Поттса с $q=4$. Класс универсальности определяется набором критических показателей теплоемкости α , намагнитченности β , восприимчивости γ , корреляционной длины ν и другими. Из гипотезы масштабной инвариантности [14, 15] следует ряд соотношений между критическими показателями [16–18]

$$2\beta + \gamma = 2 - \alpha = d\nu, \quad (2)$$

где d размерность пространства. Для класса универсальности Изинга $\alpha = 0, \beta = 1/8, \gamma = 7/4, \nu = 1$, для четырехкомпонентного Поттса $\alpha = 2/3, \beta = 1/12, \gamma = 7/6, \nu = 2/3$. Показатель ν отражает зависимость корреляционной длины при изменении линейного размера L решетки. Показатель ν и критическую температуру T_c в дальнейшем будем определять с помощью НС.

Классическим численным методом исследования фазовых переходов в решеточных спиновых моделях является метод Монте-Карло (МК). Генерация спиновых конфигураций методом МК происходит в соответствии с рекомендациями [19]. При генерации снимков конфигураций спинов подбираются параметры МК: i) время релаксации при “горячем” старте для минимизации систематической ошибки, ii) корреляционное время τ_{corr} при термодинамическом равновесии для минимизации статистической ошибки. Рассматриваются два класса алгоритмов: односпиновый алгоритм Метрополиса [20, 21] и кластерные алгоритмы Свендсена-Ванга [22] и Вольфа [23]. В алгоритме Метрополиса на каждом шаге принимается решение о выборе нового значения спина, а для кластерных – новой ориентации кластера спинов. Алгоритмы Свендсена-Ванга и Вольфа отличаются логикой формирования кластеров и эффективностью. Известно, что в критической области все алгоритмы страдают от критического замедления, при котором резко растет корреляционное время $\tau_{corr} \sim \min(L, \xi)^{d+z}$, где ξ корреляционная длина, z динамический критический показатель алгоритма. Наиболее эффективным является алгоритм Вольфа, но его реализация в модели Бакстера-Ву приводит к сдвигу T_c в низкотемпературную область, искажая результаты [24]. Был выбран алгоритм Метрополиса, наименее эффективный, но сохраняющий единый подход к генерации данных.

Вторая глава посвящена методам машинного обучения. Общая постановка задачи бинарной классификации в терминах МО – предсказать для каждого объекта $x_i \in X$ дискретное значение y_i , называемое меткой класса: $F(x_i) \rightarrow y_i$, где $y_i \in \{0, 1\}$, F решающая функция. Качество работы обученного классификатора измеряется метриками качества точности, полноты, f -меры и площади под ROC-кривой (AUCROC).

Решающей функцией F в диссертации является нейронная сеть. НС состоит из последовательных блоков, называемых слоями. Множество и порядок слоев в НС определяет её архитектуру. Каждый слой представляет собой дифференцируемую функцию. Слой имеет вход, выход и может состоять из линейных и нелинейных операторов. Основные составные элементы НС, используемые в диссертации, это полносвязные слои, сверточные слои, слои пулинга и функции активации. Предложены три архитектуры НС: полносвязная (FCNN), сверточная (CNN) и глубокая сверточная сеть ResNet [25].

Описаны основные составные элементы НС, механизмы настройки параметров сети, этапы обучения, валидации и тестирования, а также эвристики, влияющие на качество обучения. За настройку параметров отвечают механизмы обратного распространения ошибки [26, 27] и методы оптимизации на основе градиентного спуска [28]. Процесс обучения НС включает этапы разбиения данных, кодирования, контроль качества обучения и замер метрик. Эвристические подходы, позволяющие повысить метрики качества и ускорить процесс обучения: случайная иници-

ализация весов НС, пакетная обработка данных, регуляризация входного потока данных (аугментация).

В **третьей главе** описан разработанный метод для анализа фазовых переходов в решеточных спиновых моделях. Решается задача бинарной классификации методом обучения с учителем. Для исследования критического поведения решеточных спиновых моделей, методом Монте-Карло алгоритмом Метрополиса генерируются спиновые конфигурации для разных линейных размеров решеток, по 1500 изображений на каждую температурную точку. Выходной слой каждой из архитектур НС состоит из двух нейронов для ферромагнитной и парамагнитной фаз. Тренируется НС под каждый размер L с функцией потерь бинарная кросс-энтропия, по графикам кривых обучения и валидации оценивается качество процесса обучения на нескольких эпохах. Для определения критических характеристик используется отложенная выборка, которую тестируют на весах НС после первой эпохи обучения.

Для НС под каждый линейный размер L строится функция вариации выхода $V(T)$ ферромагнитного нейрона f_i^T , функция определена в каждой температурной точке T

$$V(T) = \frac{1}{N} \sum_{i=1}^N (f_i^T)^2 - \left(\frac{1}{N} \sum_{i=1}^N f_i^T \right)^2, \quad (3)$$

где $i \in \{1, 2, \dots, N\}$ снимки конфигураций спинов при T . Исследуется зависимость $V(T)$ от линейного размера L . Для каждого значения L производится процедура аппроксимации $V(T)$ ненормированной Гауссовой кривой $V(T) \sim \exp(-(T - T_*)^2/2\sigma^2)$, извлекая параметры σ и T_* . Значения ширины σ кривой $V(T)$ аппроксимируются степенным законом $\sigma(L) \sim 1/L^{1/\nu}$ для извлечения критического показателя ν . Значения положения максимума T_* кривой $V(T)$ аппроксимируются законом Фердинанда-Фишера [29] $T_*(L) - T_c \sim 1/L^{1/\nu}$, при фиксированном значении ν для извлечения оценки критической температуры \hat{T}_c при $L \rightarrow \infty$. Для моделей Изинга, Бакстера-Ву, четырехкомпонентного Поттса произведена численная оценка \hat{T}_c и ν .

Остальная часть главы посвящена трем группам экспериментов. В первой, оценивается влияние размера обучающего набора данных на точность извлекаемых показателей, путем уменьшения обучающей выборки в два и в четыре раза. Во второй, исследуется влияние количества эпох обучения НС. При длительном обучении, НС лучше решает задачу классификации, что отражается на точности извлекаемых характеристик \hat{T}_c и ν . В третьей, производится численная оценка критической температуры \hat{T}_c и критического показателя ν через обучение с переносом знания с одной модели на другую.

В **четвертой главе** исследуется влияние способов кодирования входных данных на точность извлекаемых критических характеристик. В отличии от предыдущей главы, где НС обучается в пространстве спиновых конфигураций, применяются два других способа кодирования: в пространство корреляторов спинов и в пространство энергий связей.

Для кодирования в пространство корреляторов, формируется матрица размера $L \times L$, в ячейках которой находятся корреляторы спинов. При формировании матрицы используется априорное знание о топологии решетки. Каждый спин в узле взаимодействует с другими спинами на расстоянии $L/2$ по формуле

$$g_{x,y}(L/2) = \frac{1}{D} \sum_{d=1}^D s_{x,y} s_{*}, \quad (4)$$

где $g_{x,y}(L/2)$ значение коррелятора в узле (x, y) , $s_{x,y}$ значение спина в том же узле, s_{*} значение спина стоящего на расстоянии $L/2$ от спина $s_{x,y}$ вдоль направления d , D – количество направлений, вдоль которых происходит взаимодействие.

Для кодирования в пространство энергий связей, формируются две матрицы размера $L \times L$ для хранения вертикальных $\{\sigma_V\}$ и горизонтальных $\{\sigma_H\}$ энергий связей. При формировании матриц используется априорное знание о взаимодействии между спинами:

$$\begin{aligned} \{\sigma_H\} &= \{\sigma_{i,j}\sigma_{i,j+1}, \sigma_{i,j+1}\sigma_{i,j+2}, \dots, \sigma_{i+L-1,j+L-1}\sigma_{i+L-1,j}\}, \\ \{\sigma_V\} &= \{\sigma_{i,j}\sigma_{i+1,j}, \sigma_{i+1,j}\sigma_{i+2,j}, \dots, \sigma_{i+L-1,j+L-1}\sigma_{i,j+L-1}\}. \end{aligned} \quad (5)$$

Производится полный цикл обучения НС по методу, описанному в главе 3 для извлечения оценок критической температуры T_c и критического показателя корреляционной длины ν с переносом обучения и без него. Обучение с переносом знания происходит по всем возможным комбинациям пар для моделей Изинга, Бакстера-Ву и четырехкомпонентного Поттса с кодированием в пространство энергий связей.

Положения выносимые на защиту

- Разработан метод анализа фазовых переходов в решеточных спиновых моделях на основе масштабирования функции вариации выхода нейронной сети решением задачи бинарной классификации с учителем. В методе описан процесс обучения НС, параметры, влияющие на точность извлечения критических характеристик, предложены рекомендованные значения гиперпараметров.
- Установлено, что функция вариации выхода НС, обученной по разработанному в диссертации методу, несет информацию о критическом показателе корреляционной длины ν и критической температуре \hat{T}_c тестируемой решеточной спиновой модели. Относительная погрешность при извлечении равна 0.1-0.2% для \hat{T}_c , 1-3% для ν .
- Произведена численная оценка критического показателя корреляционной длины ν и критической температуры \hat{T}_c для решеточных спиновых моделей Изинга $1/\nu = 1.02(1)$, $\hat{T}_c = 2.270(5)$; Бакстера-Ву $1/\nu = 1.49(2)$, $\hat{T}_c = 2.2691(1)$; четырехкомпонентного Поттса $1/\nu = 1.49(4)$, $\hat{T}_c = 0.9101(1)$.
- Метод численной оценки критических свойств решеточных спиновых моделей проверен с применением нескольких архитектур НС. Метод работает для полносвязной НС с одним скрытым слоем, неглубокой сверхточной НС и глубокой архитектуры ResNet с каскадом сверток. Точность работы каждой архитектуры зависит от свойств спиновой модели и гиперпараметров обучения.

- Метод численной оценки критических свойств чувствителен к гиперпараметрам обучения. Увеличение количества итераций обучения НС позволяет лучше решать задачу классификации, но ухудшает точность определения критического показателя ν . Увеличение размера обучающего набора данных не влияет на точность извлекаемых критических характеристик при достижении определенного уровня метрик качества классификации. Способ кодирования входных данных влияет на точность извлекаемых критических характеристик ν и \hat{T}_c .
- Разработан метод кодирования входных конфигураций спинов с помощью энергий связей. Произведена численная оценка критического показателя корреляционной длины ν и критической температуры \hat{T}_c для решеточных спиновых моделей Изинга, Бакстера-Ву и Поттса с $q=4$ через обучение с переносом знания внутри и вне собственного класса универсальности. Результаты совпадают с точным решением, однако метод несистемный и чувствителен к параметрам решеточных спиновых моделей, архитектурам НС и гиперпараметрам обучения.

Личный вклад автора в разработку проблемы

Гипотезы, идеи и метод были разработаны совместно с научным руководителем. Этапы генерации данных методом Монте-Карло, обучение и тестирование НС, анализ результатов нейросетевого моделирования, валидация и сравнение с классическими методами были произведены лично соискателем. В публикациях вклад соискателя определяющий. Секционные доклады на конференциях были сделаны лично соискателем.

Общие выводы исследования

- Разработан метод для исследования фазовых переходов в решеточных спиновых моделях с использованием масштабирования функции вариации выхода НС $V(T)$. Обучение НС производилось решением задачи бинарной классификации обучения с учителем. Описан общий процесс обучения НС и параметры влияющие на точность извлекаемых критических характеристик. Применив метод к моделям Изинга, Бакстера-Ву, Поттса с $q=4$, были получены количественные оценки для критического показателя $1/\nu$ и критической температуры \hat{T}_c . Относительная погрешность работы метода для извлечения критической температуры \hat{T}_c в пределах 0.2%, критического показателя ν в пределах 3%, что превосходит остальные подходы МО в решеточных спиновых моделях. Значения показателей ν и \hat{T}_c в пределах статистической погрешности совпадают с точным аналитическим решением для этих моделей в классах универсальности Изинга и четырехкомпонентного Поттса.
- Анализ **архитектур** НС, от неглубоких к глубоким показал, что метод работает систематически. Однако, среди архитектур нельзя выбрать наилучшую, потому что их отличия в точности работы зависят от свойств исследуемых

решеточных спиновых моделей, методов кодирования входных данных и способа исследования (с переносом обучения или без). При обучении на конфигурациях спинов более точные решения для \hat{T}_c, ν дают менее глубокие архитектуры FCNN и CNN, что согласуется с наблюдениями других исследователей [30]. При кодировании спиновых конфигураций в пространство энергий связей, архитектура FCNN сталкивается с недообучением, а точность работы CNN и ResNet не отличается друг от друга.

- Исследование влияния **количества эпох** при обучении показало, что при росте количества эпох, НС лучше решает задачу классификации, но хуже извлекает критический показатель ν , а на поздних эпохах превращается в идеальный классификатор без возможности извлекать ν . **Размер** набора данных при обучении НС может влиять на точность извлекаемых показателей до достижения определенного уровня метрик качества классификации. FCNN в модели Изинга при обучении на четверти выборки, сталкивается с недообучением по метрике AUCROC, что приводит к ухудшению извлекаемого показателя ν .
- Произведена численная оценка критического показателя корреляционной длины ν и критической температуры \hat{T}_c для решеточных спиновых моделей Изинга, Бакстера-Ву и Поттса с $q=4$ через обучение с переносом знания внутри и вне собственного класса универсальности. Перекрестное обучение работает менее систематически, чем тестирование на собственной модели. Критическая температура \hat{T}_c извлекается систематически, для всех сочетаний обучения и тестирования РСМ, за исключением переноса знания с квадратной решетки на треугольную в пространстве спиновых конфигураций. Относительная погрешность составляет 0.1-1.5% в пространстве спиновых конфигураций, и 0.1-5% в пространстве энергий связей. Наибольшая относительная погрешность извлечения \hat{T}_c при переносе знания с модели Поттса: 0.3-4% внутри класса универсальности, 7-16% между классами универсальности. Критический показатель корреляционной длины ν извлекается менее постоянно. В пространстве спиновых конфигураций перенос знания возможен только с класса универсальности Поттса на класс универсальности Изинга, и не возможен с квадратной решетки на треугольную. При использовании кодирования с помощью энергий связей, возможно перенести знание о фазовом переходе с модели Изинга на модель Бакстера-Ву с точностью как при собственном тестировании модели. При переходе от спиновых конфигураций в пространство энергий связей, НС не нужно “понимать” пространственное расположение спинов на решетке, проблема с которой сталкивались сети при переносе знания с квадратной решетки на треугольную. Кодирование спиновых конфигураций в пространство корреляторов и энергий связей происходит с внесением в НС дополнительной информации о топологии решетки и Гамильтониане взаимодействий в модели.

Апробация результатов

Публикации:

- Chertentkov V .I. Universality classes and machine learning / Shchur L.N. // Journal of Physics: Conference Series. 2021. N 1740. P. 1-5. (Scopus Q4)
- Chertentkov V .I. Deep machine learning investigation of phase transitions / Burovski E.A., Shchur L.N. // Lecture Notes in Computer Science. 2022. N 13708. P. 397-408. (Scopus Q2)
- Chertentkov V .I. Finite-size analysis in neural network classification of critical phenomena / Burovski E.A., Shchur L.N. // Physical Review E - Statistical, Nonlinear, and Soft Matter Physics. 2023. T. 108. N 3. P. 1-5. (Scopus Q1)
- Sukhoverhova D.D. Validity and limitations of supervised learning for phase transition research / Chertentkov V .I., Burovski E.A., Shchur L.N. // Lecture Notes in Computer Science. 2023. N 14389. P. 314-329. (Scopus Q2)

Секционные доклады:

- IV Международная конференция «Компьютерное моделирование в физике и не только», Россия, Москва, 12-16 октября 2020 г., “Universality classes and machine learning”.
- Международная конференция «Суперкомпьютерные дни в России», Россия, Москва, 26-27 сентября 2022 г., “Deep machine learning investigation of phase transitions”.
- Межвузовская научно-техническая конференция студентов, аспирантов и молодых специалистов им. Е.В.Арменского, Россия, Москва, 27 февраля – 7 марта 2023 г., “Исследование спиновых моделей с помощью методов машинного обучения”.
- Национальный Суперкомпьютерный Форум НСКФ-2023, Россия, Переславль-Залесский, 28 ноября – 1 декабря 2023 г., “Influence of learning protocols on deep learning studies of phase transitions”.
- НИС Вычислительные среды, Москва, МИЭМ НИУ ВШЭ, 14 ноября 2023, “Unsupervised learning of phase transitions via modified anomaly detection with autoencoders”.
- Международная конференция «Суперкомпьютерные дни в России», Россия, Москва, 23-24 сентября 2024 г., “Supervised and Transfer Learning for Phase Transition Research”.

Зарегистрированное программное обеспечение:

- “Система исследования фазовых переходов в решеточных спиновых моделях”.

Список литературы

- [1] Juan Carrasquilla и Roger G Melko. “Machine learning phases of matter”. В: *Nature Physics* 13.5 (2017), с. 431—434.
- [2] Gordon Frank Newell. “Crystal statistics of a two-dimensional triangular Ising lattice”. В: *Physical Review* 79.5 (1950), с. 876.
- [3] Kimihiko Fukushima и Kazumitsu Sakai. “Can a CNN trained on the Ising model detect the phase transition of the q-state Potts model?” В: *Progress of Theoretical and Experimental Physics* 2021.6 (2021), 061A01.
- [4] Nicholas Walker и Ka-Ming Tam. “InfoCGAN classification of 2D square Ising configurations”. В: *Machine Learning: Science and Technology* 2.2 (2020), с. 025001.
- [5] Constantia Alexandrou и др. “The critical temperature of the 2D-Ising model through deep learning autoencoders”. В: *The European Physical Journal B* 93 (2020), с. 1—15.
- [6] Wanzhou Zhang, Jiayu Liu и Tzu-Chieh Wei. “Machine learning of phase transitions in the percolation and X Y models”. В: *Physical Review E* 99.3 (2019), с. 032142.
- [7] Yusuke Miyajima и др. “Machine learning detection of Berezinskii-Kosterlitz-Thouless transitions in q-state clock models”. В: *Physical Review B* 104.7 (2021), с. 075114.
- [8] Kenta Shiina и др. “Machine-learning studies on spin models”. В: *Scientific reports* 10.1 (2020), с. 2177.
- [9] Dimitrios Bachtis, Gert Aarts и Biagio Lucini. “Mapping distinct phase transitions to a neural network”. В: *Physical Review E* 102.5 (2020), с. 053306.
- [10] Ernst Ising. “Beitrag zur theorie des ferro-und paramagnetismus”. Дис. . . . док. Grefe & Tiedemann Hamburg, Germany, 1924.
- [11] Lars Onsager. “Crystal statistics. I. A two-dimensional model with an order-disorder transition”. В: *Physical Review* 65.3-4 (1944), с. 117.
- [12] RJ Baxter и FY Wu. “Exact solution of an Ising model with three-spin interactions on a triangular lattice”. В: *Physical Review Letters* 31.21 (1973), с. 1294.
- [13] Renfrey Burnard Potts. “Some generalized order-disorder transformations”. В: *Mathematical proceedings of the cambridge philosophical society*. Т. 48. 1. Cambridge University Press. 1952, с. 106—109.
- [14] Leo P Kadanoff. “Scaling laws for Ising models near T c”. В: *Physics Physique Fizika* 2.6 (1966), с. 263.
- [15] АЗ Паташинский и ВЛ Покровский. “О поведении упорядочивающихся систем вблизи точек фазового перехода”. В: *ЖЭТФ* 50.2 (1966), с. 439—447.
- [16] Benjamin Widom. “Equation of state in the neighborhood of the critical point”. В: *The Journal of Chemical Physics* 43.11 (1965), с. 3898—3905.
- [17] Michael E Fisher. “The theory of equilibrium critical phenomena”. В: *Reports on progress in physics* 30.2 (1967), с. 615.
- [18] Leo P Kadanoff и др. “Static phenomena near critical points: theory and experiment”. В: *Reviews of Modern Physics* 39.2 (1967), с. 395.

- [19] Alan Sokal. “Monte Carlo methods in statistical mechanics: foundations and new algorithms”. В: *Functional integration: Basics and applications*. Springer, 1997, с. 131—192.
- [20] W Keith Hastings. “Monte Carlo sampling methods using Markov chains and their applications”. В: (1970).
- [21] Nicholas Metropolis и др. “Equation of state calculations by fast computing machines”. В: *The journal of chemical physics* 21.6 (1953), с. 1087—1092.
- [22] Robert H Swendsen и Jian-Sheng Wang. “Nonuniversal critical dynamics in Monte Carlo simulations”. В: *Physical review letters* 58.2 (1987), с. 86.
- [23] Ulli Wolff. “Collective Monte Carlo updating for spin systems”. В: *Physical Review Letters* 62.4 (1989), с. 361.
- [24] Lev N Shchur и Wolfhard Janke. “Critical amplitude ratios of the Baxter–Wu model”. В: *Nuclear Physics B* 840.3 (2010), с. 491—512.
- [25] Kaiming He и др. “Deep residual learning for image recognition”. В: *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016, с. 770—778.
- [26] Paul Werbos. “Beyond regression: New tools for prediction and analysis in the behavioral sciences”. В: *PhD thesis, Committee on Applied Mathematics, Harvard University, Cambridge, MA* (1974).
- [27] David E Rumelhart, Geoffrey E Hinton и Ronald J Williams. “Learning representations by back-propagating errors”. В: *nature* 323.6088 (1986), с. 533—536.
- [28] Diederik P Kingma и Jimmy Ba. “Adam: A method for stochastic optimization”. В: *arXiv preprint arXiv:1412.6980* (2014).
- [29] Arthur E Ferdinand и Michael E Fisher. “Bounded and inhomogeneous Ising models. I. Specific-heat anomaly of a finite lattice”. В: *Physical Review* 185.2 (1969), с. 832.
- [30] Alan Morningstar и Roger G Melko. “Deep learning the ising model near criticality”. В: *Journal of Machine Learning Research* 18.163 (2018), с. 1—17.