

К 270-летию МОСКОВСКОГО ГОСУДАРСТВЕННОГО УНИВЕРСИТЕТА (МГУ)
имени М.В. ЛОМОНОСОВА

ФИЗИКА НАШИХ ДНЕЙ

Методы машинного обучения в физике Солнца

Е.А. Илларионов

Развитие и успехи методов машинного обучения в широком круге задач оказали существенное влияние на постановку и проведение научных исследований в солнечной физике. Большие массивы данных стали самостоятельной ценностью, в которую вложены усилия экспертов и значительные технологические ресурсы. Сами исследования приобрели междисциплинарный характер и концентрируются вокруг передовых вычислительных центров. Появилась возможность ставить масштабные задачи там, где ещё вчера отсутствовала чёткая математическая постановка. В обзоре представлены основные идеи, на которых основаны современные модели машинного обучения, базы данных, подготовленные для задач машинного обучения, и инструменты работы с данными. Основная часть обзора посвящена обсуждению моделей, предложенных в контексте конкретных задач физики Солнца, и их обобщений на другие приложения.

Ключевые слова: Солнечная физика, солнечная активность, машинное обучение, базы данных

PACS numbers: 07.05.Mh, 84.35.+i, 96.60.-j

DOI: <https://doi.org/10.3367/UFNr.2025.02.039872>

Содержание

1. Введение (395).
 2. Основные идеи машинного обучения (396).
 - 2.1. Модель данных.
 - 2.2. Задача обучения и функция потерь.
 - 2.3. Минимизация функции потерь.
 3. Наборы данных для машинного обучения (401).
 4. Программы для работы с данными (403).
 5. Модели машинного обучения в физике Солнца (404).
 - 5.1. Сегментация изображений солнечного диска.
 - 5.2. Параметрическое описание данных.
 - 5.3. Прогноз солнечной активности.
 - 5.4. Реконструкция наблюдательных данных.
 - 5.5. Моделирование динамических процессов.
 6. Заключение (413).
- Список литературы (414).

1. Введение

Методы машинного обучения становятся всё более популярным и эффективным инструментом в задачах, связанных с обработкой данных. Пожалуй, один из самых заметных результатов — это модели обработки естественного языка, применяемые, например, при машинном переводе. Интересно, что сегодня модели естественного языка являются одной из основных движущих

сил в машинном обучении. Многие современные модели для обработки изображений, видео и других форматов данных были впервые предложены для обработки текста. Аналогичную ситуацию можно найти и в истории. Как известно, первым ярким применением цепей Маркова был статистический анализ литературного текста [1], но затем эта модель оказалась востребована в гораздо более широком круге задач. В качестве современного примера можно привести архитектуру нейронной сети типа трансформер (Transformer, [2]). Модель была предложена в контексте машинного перевода и легла в основу языковых моделей, ставших сегодня наиболее популярными и передовыми: BERT (Bidirectional Encoder Representations from Transformers, [3]), GPT (Generative Pre-trained Transformer, [4]) и ряд других. Недавно были предложены адаптации для работы с изображениями (VisualTransformer, [5]), видео (VideoGPT, [6]) и другими задачами (см. обзор [7]). Упомянутые выше языковые модели тесно связаны с ещё одним важным понятием, сформировавшимся преимущественно в контексте моделей обработки естественного языка — концепции фундаментальных моделей машинного обучения (Foundation models). Суть состоит в том, что вместо обучения индивидуальных моделей под каждую конкретную задачу, обучается одна, в некотором смысле универсальная, модель сразу под множество задач. Сегодня такой подход активно развивается в самых различных приложениях (см. обзор [8]).

Разумеется, результаты, которые показывают методы машинного обучения в задачах повседневных, вдохновляют на поиски приложений в более специализированных областях. Целью настоящей статьи будет обзор приложений в задачах, связанных с изучением солнечной

Е.А. Илларионов

Московский государственный университет им. М.В. Ломоносова,
механико-математический факультет,
Ленинские горы 1, 119991 Москва, Российская Федерация
E-mail: egor.illarionov@math.msu.ru

Статья поступила 5 августа 2024 г.

активности. Акцент будет сделан на том, чтобы показать вариативность проблем, для решения которых могут быть полезны модели машинного обучения, и показать примеры их решения. Обсуждение детальных отличий различных решений одной проблемы и сравнение качества подходов выходит за рамки работы, поскольку требует более основательного погружения в тонкие детали природы данных, строения моделей и критериев качества.

Сама по себе идея использования методов машинного обучения в физике Солнца не является обоснованной. Одной из важнейших предпосылок, дающих основание рассчитывать, что полученная модель будет жизнеспособной, является наличие большого массива данных с примерами желаемого результата решения задачи. Физика Солнца в этом смысле является богатым источником как разнообразных задач, так и массивов наблюдательных данных. Появление первых систематических данных о солнечной активности принято связывать с серией записей и зарисовок солнечного диска и положения солнечных пятен, выполненных Галилео Галилеем в 1612 г. Хотя недавно были восстановлены и несколько более ранние серии зарисовок, сделанные Томасом Хариотом в конце 1610–начале 1613 гг. (см. [9]). Так или иначе, к сегодняшнему дню исторический ряд данных превышает 400 лет, что является уникальным по продолжительности для научных измерений в целом. Конечно, историческим данным присуща своя неопределённость и нерегулярность, которая затрудняет их анализ, однако они помогают понять долговременные особенности динамики солнечной активности. Современные наземные и спутниковые телескопы в совокупности обеспечивают практически непрерывный мониторинг солнечного диска с высоким (вплоть до нескольких десятков километров, телескоп DKIST, [10]) пространственным разрешением и в различных частях спектра (белый свет, ультрафиолетовый (УФ) и рентгеновский диапазоны, радиодиапазон, магнитограммы). Всё это позволяет в деталях изучать процессы формирования и развития активных областей на Солнце.

Большой временной охват и высокая пространственно-временная детализация, достигнутая к сегодняшнему дню, дают основу для проведения разнообразных статистических исследований. Однако на практике анализ наблюдательных данных существенно затрудняется рядом факторов. Одним из них является неоднородность данных. За 400 лет сменялись наблюдатели, совершенствовалась техника и происходила эволюция представлений о том, что и как следует наблюдать. В результате возникает вопрос о согласовании более ранних и более поздних наблюдений и, как следствие, разнообразные дискуссии на этот счёт. Например, ряд чисел Вольфа, составляемый из отдельных серий наблюдений групп солнечных пятен, не раз подвергался пересмотру, в результате которого существенно видоизменялся (см., например, [11]).

Существенной проблемой также является доступность и полнота данных. Большой пласт исторических данных до сих пор находится в бумажных архивах, а многое из того, что удалось отсканировать в электронный вид, требует оцифровки рукописного текста и зарисовок. Поскольку многие детали того, как проводились наблюдения в отдалённый исторический период, нам неизвестны, этап оцифровки зачастую одновре-

менно является и этапом реконструкции методик наблюдений.

Современные наблюдательные данные, с одной стороны, лишены многих проблем, которые возникают при работе с историческими данными: они сразу представлены в цифровом виде, значительно более однородны (хотя известна проблема деградации измерительных инструментов) и регулярны. Но, несмотря на это, нельзя сказать, что они систематически изучены. Основная причина — большой физический объём данных, пополняемый ежедневно потоками новых данных. В качестве примера можно привести один только спутник SDO (Solar Dynamics Observatory, [12]), работающий с 2010 г. по сей день и проводящий съёмку солнечного диска каждые 12 секунд.

Можно сделать вывод, что извлечение полезной информации из больших объёмов данных является вызовом для современной науки и вычислительных технологий. Методы машинного обучения, как показывает практика, являются одним из эффективных способов достижения этой цели.

Далее напомним основные идеи методов машинного обучения и перейдём к рассмотрению примеров их использования в физике Солнца.

2. Основные идеи машинного обучения

2.1. Модель данных

Типичным примером возникновения задачи машинного обучения является задача описания некоторой наблюдаемой зависимости в функциональной форме (построения модели данных). Если при этом желательно предложить общий подход для решения не одной, а целого класса подобных задач, то природа и детали наблюдаемой зависимости в конкретный момент должны быть не важны. Вместо этого необходимо выбрать параметрическое семейство функций (часто также употребляют термин модель), достаточно широкое, чтобы охватить любую возможную зависимость. В качестве примера такого семейства можно привести полиномы, с помощью которых, как известно, можно приближать с любой точностью непрерывные на отрезке функции.

Оставаясь безупречными с математической точки зрения, многие конструкции становятся сложными с вычислительной точки зрения при работе в пространствах высокой размерности (например, возникающие произведения большого числа полиномов могут быстро выходить за пределы машинной точности). Отметим, что пространства высокой размерности — это не уникальный, а, напротив, скорее типичный случай в современных задачах обработки данных. Например, в задаче классификации изображений, являющихся, по сути, числовыми матрицами, изображения интерпретируются как объекты в пространстве с размерностью, равной числу элементов в матрице. Для снимков высокого разрешения такое число может составлять несколько миллионов. Таким образом, возникает вопрос о поиске более удобного и универсального с вычислительной точки зрения способа аппроксимации функций.

Важное представление о функциях в пространствах произвольной размерности было получено А.Н. Колмогоровым. В работе [13] было показано, что любая непрерывная внутри n -мерного единичного куба функция




Рис. 1. Иллюстрация представления функции суперпозицией функций одной переменной, согласно теореме Колмогорова [13].

может быть представлена конечной композицией функций одного аргумента:

$$f(x_1, x_2, \dots, x_n) = \sum_{k=1}^{2n+1} \varphi_k \left(\sum_{i=1}^n \psi_{i,k}(x_i) \right), \quad (1)$$

причём функции $\psi_{i,k}$ не зависят от функции f , а только от размерности n . Можно сказать, что они образуют универсальный базис. Функции φ_k , конечно, зависят от функции f .

Фактически, функции от n аргументов можно представить в виде достаточно простого вычислительного графа, как показано на рис. 1, причём число узлов лишь линейно зависит от размерности пространства. Таким образом, опираясь на эту теорему, можно надеяться найти приближение функции с помощью конечного (и вполне обозримого) числа простых (в том смысле, что они зависят от одного аргумента) функций. Практическая реализация данной теоремы была предложена совсем недавно в работе [14], но она пока ещё не лишена недостатков, и поэтому говорить о её массовом применении пока рано.

С практической точки зрения большое значение имел результат, полученный несколько позднее в теореме Цыбенко ([15], стоит отметить, что в тот же год такой же результат был независимо получен в работах [16, 17]). Теорема Цыбенко утверждает, что непрерывные (внутри n -мерного единичного куба) функции можно аппроксимировать с любой наперёд заданной точностью с помощью композиции сигмоидных функций

$$f(x_1, x_2, \dots, x_n) \approx \sum_k \alpha_k \sigma \left(\sum_{i=1}^n \gamma_{i,k} x_i + \beta_k \right), \quad (2)$$

где $\gamma_{i,k}$, α_k и β_k — константы, зависящие от f , а σ — некоторая наперёд заданная непрерывная неубывающая на всей прямой и ограниченная функция. Часто в качестве такой функции берут

$$\sigma(x) = \frac{1}{1 + \exp(-x)}, \quad (3)$$

известную как логистическая функция или сигмоида. Соответствующий вычислительный граф показан на рис. 2. Внешне он очень похож на тот, что показан на рис. 1. Существенным отличием является то, что количе-




Рис. 2. Аппроксимация функции суперпозицией сигмоидных функций, согласно теореме Цыбенко [15].

ство узлов во втором случае заранее не оговаривается и может быть достаточно большим для точной аппроксимации, однако вместо неизвестных функций участвуют неизвестные скалярные параметры, с которыми значительно проще работать. Сегодня этот вычислительный граф принято называть полносвязной нейросетевой моделью с одним скрытым слоем и функцией активации σ . Соответственно, про теорему Цыбенко говорят как про теорему об "универсальной аппроксимации нейронными сетями". Узлы графа называют нейронами, а конкретное строение графа (число нейронов, слоёв и связей) — архитектурой нейронной сети. Забегая вперёд, отметим, что современные архитектуры имеют большое число слоёв и сложно устроенные связи. Дальнейшее обсуждение теоретических вопросов см., например, в работах [18, 19].

В настоящем обзоре мы ограничимся рассмотрением приложений моделей машинного обучения, основанных на нейронных сетях, хотя, разумеется, только ими набор методов машинного обучения далеко не исчерпывается. Систематический обзор можно найти, например, в книгах [20–22]. Отметим лишь, что общие принципы остаются едиными.

2.2. Задача обучения и функция потерь

Модель данных, основанная на нейронных сетях, задаёт целое семейство функций. Выбор одной конкретной функции определяется выбором конкретных значений для параметров модели. Для выбора таких значений необходимо сформулировать критерии, которым должна удовлетворять искомая функция. Математически это реализуется так, что формулируется некоторый функционал (часто его называют функцией потерь или функцией риска), минимум которого достигается на искомой функции, и решается оптимизационная задача. Составляемый функционал может включать в себя наблюдательные данные, физические соотношения (например, дифференциальные уравнения), различного вида ограничения на значения функции и другие слагаемые. Рассмотрим некоторые важнейшие примеры.

2.2.1. Классификация и регрессия. Типичная задача состоит в том, что по имеющимся данным в виде пар наблюдений (x_i, y_i) , где индекс i показывает номер наблюдения, необходимо предложить функцию $f(x)$, которая приближает наблюдаемые значения второй перемен-

ной y . Так может формулироваться задача бинарной классификации (в этом случае y принимает всего два значения, например, 0 или 1), многоклассовой классификации (y имеет дискретную природу и больше чем два возможных значения) или регрессии (y имеет непрерывную природу). Обозначив модель данных в виде $f(x, \theta)$, где θ — набор параметров модели, можно предложить в качестве функции потерь усреднение по всем наблюдениям

- для задачи регрессии — квадрата разности $l(\theta) = (y_i - f(x_i, \theta))^2$;

- для задачи бинарной классификации — бинарную кросс-энтропию $l(\theta) = -y_i \log f(x_i, \theta) - (1 - y_i) \log (1 - f(x_i, \theta))$. При этом предполагается, что значения $f(x_i, \theta)$ неотрицательны и не превосходят 1;

- для задачи классификации на K классов — кросс-энтропию $l(\theta) = -\sum_{k=1}^K y_{i,k} \log f_k(x_i, \theta)$. Здесь $y_{i,k} = 1$, если $y_i = k$, и 0 — если иначе. Также предполагается, что $f_k(x_i, \theta)$ неотрицательны и в сумме по k дают 1.

Приведённые выше функции, конечно, не являются единственно возможными. Их можно назвать каноническими с той точки зрения, что они возникают из оценок максимального правдоподобия. Например, среднеквадратичная функция потерь возникает в предположении, что наблюдения y_i независимы и распределены по нормальному (гауссову) закону, в котором среднее (математическое ожидание) есть функция от x_i и параметров θ . Полезно также отметить, что все три случая (регрессия, бинарная и многоклассовая классификация), несмотря на внешнее различие, могут быть объединены в одну модель и изучаться в рамках единой теории обобщённой линейной модели с использованием аппарата теории вероятностей и математической статистики (слово "линейность" никак не ограничивает рассмотрение нелинейных зависимостей). Подробнее про вероятностный контекст моделей машинного обучения см. книги [20, 22].

Отдельно стоит отметить, что в ряде задач, формально относящихся к классификации или регрессии, выбор рассмотренных выше функций может не вполне отвечать природе задачи. В качестве примера рассмотрим ситуацию, когда y_i являются изображениями (здесь можно представить себе любую фотографию), и мысленно сдвинем всё изображение на один пиксель вправо. С точки зрения восприятия оба изображения будут почти неотличимы, в то же время среднеквадратичное расстояние между ними может быть большим (например, больше, чем между двумя "на глаз" непохожими изображениями). В таких случаях используют более специфичные метрики. Например, в контексте изображений это могут быть метрики, вычисляемые не напрямую между значениями пикселей, а между некоторыми более сложными характеристиками двух изображений (см., например, perceptual loss [23]).

2.2.2. Физически информированные нейронные сети. Задачи классификации и регрессии являются базовыми в том смысле, что к ним, так или иначе, сводятся другие задачи, изначальная формулировка которых может сильно отличаться от задачи прогноза y по значениям x . В качестве примера рассмотрим задачу численного решения дифференциальных уравнений. Для определённости рассмотрим обыкновенное дифференциальное уравнение на функцию $y(x)$ в виде $F(x, y, y', \dots, y^{(n)}) = 0$ с начальным

условием $y(x_0) = y_0$. Эту задачу можно решать методом конечных разностей и его разновидностями (см. [24]). Однако на неё можно посмотреть и с точки зрения машинного обучения. Используя тот факт, что нейронные сети являются универсальным аппроксиматором, зададим искомую функцию $y(x)$ в виде нейронной сети и будем подбирать её параметры так, чтобы функция $y(x)$ как можно точнее удовлетворяла заданному дифференциальному уравнению. Здесь полезно отметить, что по построению функция, представленная нейронной сетью, является дифференцируемой как по параметрам, так и по входным переменным. Причём все производные вычисляются методами автоматического дифференцирования (см. ниже). Таким образом, если задать $y(x)$ нейронной сетью $y(x, \theta)$, то становятся определёнными и все производные $y^{(n)}$. Далее, для составления функции потерь обычно берут набор случайных точек x_i из области определения $y(x)$ и вычисляют средний квадрат невязки между левой и правой частью уравнения в этих точках: $l(\theta) = F^2(x_i, y(x_i, \theta), y'(x_i, \theta), \dots, y^{(n)}(x_i, \theta))$ (напомним, что в правой части уравнения стоит нуль, поэтому всё сводится к квадрату значения F). Для учёта начального условия в функцию ошибки добавляют слагаемое вида $(y(x_0, \theta) - y_0)^2$ с некоторым коэффициентом, регулирующим вклад данного слагаемого в функцию ошибки.

Нетрудно видеть, что задача решения дифференциального уравнения свелась к задаче регрессии. Однако более интересный вывод получается, если попытаться объединить задачи регрессии по наблюдаемым парам (x_i, y_i) и решения дифференциального уравнения. Иными словами, предполагается, что наблюдаемая зависимость y от x подчиняется с некоторой точностью заданному дифференциальному уравнению. Соответственно подбирать зависимость $y(x)$ можно путём минимизации составной функции потерь

$$l(\theta) = \frac{1}{n} \sum_{i=1}^n (y(x_i) - y_i)^2 + \frac{\alpha}{m} \sum_{j=1}^m F^2(x_j, y(x_j), y'(x_j), \dots, y^{(n)}(x_j)). \quad (4)$$

Здесь для простоты аргумент θ опущен, n — объём выборки наблюдательных данных, m — количество точек, в которых оценивается точность решения дифференциального уравнения, а коэффициент α регулирует соотношение двух слагаемых. Подобная конструкция получила название физически-информированных нейронных сетей (PINN, [25]). Заметим, что априорная физическая модель данных в виде дифференциального уравнения выступает в качестве дополнительного ограничения (или, как часто говорят, регуляризатора) на спектр возможных зависимостей $y(x)$, стоящих за наблюдаемыми данными. В частности, этот подход может помогать бороться с проблемой переобучения модели (когда ошибка на обучающих данных значительно меньше, чем на тестовых) и повышать устойчивость при прогнозе для новых данных.

В качестве примера рассмотрим задачу, когда обучающая выборка получается из синусоиды, к которой прибавлен случайный гауссов шум (рис. 3). Возьмём две одинаковые полносвязные модели нейронной сети и обучим первую, используя в качестве функции потерь




Рис. 3. Регрессия на основе обучающей выборки (чёрные точки) с помощью модели физически информированной нейронной сети (PINN, красная линия) и обычной нейронной сети (NN, синяя линия). Архитектура модели одинакова в обоих случаях. Физически информированная нейронная сеть опирается при обучении на уравнение $y'(x) = \cos x$.

сумму среднеквадратичной ошибки на обучающей выборке и ошибки от решения дифференциального уравнения $y'(x) = \cos x$, а вторую модель будем обучать только на основе среднеквадратичной ошибки на обучающей выборке. Рисунок 3 показывает, что вторая модель в большей степени подстраивается под наблюдательные данные, в то время как первая балансирует между физической моделью и наблюдательными данными. Особенно заметно различие в той области, где наблюдений нет.

Существуют и другие методы регуляризации моделей. Например, к функции потерь добавляются дополнительные слагаемые, характеризующие амплитуду параметров модели: сумма квадратов параметров модели (так называемая L_2 -регуляризация, или гребневая регуляризация, или регуляризация Тихонова) или сумма модулей (L_1 , или лассо-регуляризация). Более сложные конструкции см. в [26].

2.2.3. Нейро-дифференциальные уравнения. От задачи решения дифференциального уравнения перейдём к обратной задаче: по наблюдениям процесса в некоторые моменты времени восстановить дифференциальное уравнение, моделирующее этот процесс. Математическая постановка задачи вновь сводится к формулировке функции потерь. Предположим, что наблюдаемый процесс подчиняется уравнению

$$\frac{df(t)}{dt} = g(f(t), t) \quad (5)$$

с неизвестной функцией $g(\cdot, \cdot)$, которую зададим нейронной сетью $g(\cdot, \cdot, \theta)$. Будем решать уравнение стандартными численными схемами и варьировать параметры нейронной сети так, чтобы результат решения согласовывался с наблюдательными данными. Для составления функции потерь обозначим через $\text{ODESolve}(g, t_0, f_0, t)$ численную схему, принимающую на вход функцию из правой части уравнения (5), начальные данные (t_0, f_0) и момент времени t , на который ищется решение. Пусть $\{(t_i, f_i)\}_{i=1}^n$ — набор наблюдаемых значений процесса. Тогда в качестве функции потерь можно вновь использо-

вать среднеквадратичную ошибку

$$l(\theta) = \frac{1}{n} \sum_{i=1}^n (\text{ODESolve}(g, t_0, f_0, t_i) - f_i)^2. \quad (6)$$

Такой подход получил название нейро-дифференциальные уравнения (Neural-Differential Equations, NDE [27]). Отметим, что основным моментом является процедура вычисления градиента функции потерь $l(\theta)$ по параметрам θ без необходимости прямого дифференцирования функции ODESolve . Для этого составляется вспомогательное (сопряжённое, см. [28]) дифференциальное уравнение, решение которого даёт значение $dl/d\theta$.

2.2.4. Автоэнкодеры. Многие виды наблюдательных данных, например изображения, профили спектральных линий, являются объектами в пространствах высокой размерности (изображения задаются числовыми матрицами, линии — набором значений на каждой длине волны). Для анализа подобных объектов было бы удобно иметь их описание в более компактной форме — с помощью меньшего числа параметров, но характеризующих наиболее значимые признаки. Математически такая задача созвучна задаче понижения размерности данных. Чтобы эта задача стала осмысленна, можно потребовать, чтобы отображение объекта в пространство меньшей размерности было почти обратимым, т.е. была возможность обратного восстановления исходного образа. Тогда можно утверждать, что низкоразмерное представление сохраняет информацию про исходный объект. Одним из распространённых стандартных приёмов решения этой задачи является метод главных компонент (Principal Component Analysis, PCA), предложенный К. Пирсоном в работе 1901 г. [29]. Однако поскольку указанный метод является линейным, можно предположить, что его эффективность на данных сложной структуры будет недостаточной (обсуждение особенностей метода PCA можно найти в работе [30]). Возникает интерес к поиску нелинейных методов и, как возможное решение, — модель автоэнкодера. Модель состоит из двух функций, заданных нейронными сетями. Одна из них, обозначим её $\text{Enc}(x, \theta)$, называется энкодером и отображает x в вектор $z = \text{Enc}(x)$ меньшей размерности. Вектор z называют скрытым или латентным представлением вектора x . Вторая функция — декодер $\text{Dec}(z, \tilde{\theta})$ — отображает векторы из скрытого пространства в исходное $\tilde{x} = \text{Dec}(z)$. В простейшей реализации для обучения модели требуют, чтобы композиция декодера и энкодера $\text{Dec}(\text{Enc}(x))$ была как можно ближе к тождественному преобразованию. Соответственно, возникает функция потерь

$$l(\theta, \tilde{\theta}) = \frac{1}{n} \sum_{i=1}^n (\text{Dec}(\text{Enc}(x_i)) - x_i)^2, \quad (7)$$

где $\{x_i\}_{i=1}^n$ — набор данных для обучения. Существуют различные модификации модели автоэнкодера, в которых, например, накладываются дополнительные ограничения на характер распределения векторов в скрытом пространстве. В качестве примера приведём вариационный автоэнкодер (Variational Autoencoder, VAE), предложенный в работе [31]. В нём используется дополнительное слагаемое в функции потерь, отвечающее за близость распределения латентных векторов к стандарт-

ному многомерному гауссову распределению. Дополнительный обзор можно найти в работе [32].

В контексте моделей типа вариационного автоэнкодера стоит также упомянуть про модели, получившие название нормализующие потоки (Normalizing Flows, [33]). Их основная задача — подобрать строго обратимое преобразование, переводящее распределение, порождённое выборкой, в стандартное гауссово. Соответственно, размерности скрытого и исходного пространства задаются равными, а нейронная сеть составляется так, чтобы для неё просто выписывалось обратное преобразование. Более детальный обзор см. в работе [34]. Одним из приложений нормализующих потоков является генерация синтетических данных. Для этого моделируется выборка из гауссова распределения, которая затем с помощью обратного к нормализующему потоку отображения переводится в исходное пространство, и таким образом возникает новая синтетическая выборка. Тем же приёмом можно моделировать синтетические данные, используя декодер предварительно обученного вариационного автоэнкодера.

2.2.5. Генеративные модели. Обсудим более подробно генеративные модели. Их задачей является создание новых выборок данных, неотличимых по свойствам, но не буквально, от выборки реальных данных. Математически это означает, что выборка, полученная из модели, имеет такое же распределение, как и у выборки реальных данных. Полученные синтетические выборки могут быть полезны, например, в качестве начальных данных при математическом моделировании динамических систем.

Обычно генеративная модель (Generative-Adversarial Network, GAN) состоит из двух частей, реализованных с помощью нейронных сетей. Одна часть называется генератором $G(z, \theta)$ и отображает пространство, в котором моделируется выборка z_i из стандартного гауссова закона, в пространство, в котором задана реальная выборка x_i . Вторая модель называется дискриминатором $D(x, \theta)$ и представляет из себя бинарный классификатор, который должен отличать синтетический пример от реального. Обе модели, генератор и дискриминатор, имеют конкурирующие задачи. Генератор должен учиться выдавать примеры, которые с точки зрения дискриминатора классифицируются как реальные, а дискриминатор, напротив, должен учиться как можно лучше классифицировать реальные и синтетические данные. На этой игре составляется функция потерь для генератора

$$l(\theta) = -\frac{1}{n} \sum_{i=1}^n \log [1 - D(G(z_i))], \quad (8)$$

которая будет тем меньше (обратим внимание на знак минус перед формулой), чем чаще дискриминатор будет ошибаться и классифицировать синтетические данные как реальные (полагается, что реальным данным соответствует нулевой класс, а синтетическим — первый). Функция потерь для дискриминатора имеет вид

$$l(\tilde{\theta}) = \frac{1}{n} \sum_{i=1}^n \log D(x_i) + \log [1 - D(G(z_i))]. \quad (9)$$

Первое слагаемое будет тем меньше, чем точнее дискриминатор классифицирует реальные данные как реальные, а второе — чем точнее классифицирует синтетические

примеры как синтетические. Данная функция потерь была предложена в работе [35]; современные реализации используют более сложные конструкции (см., например, [36]).

Приведённые выше примеры задач и соответствующих функций потерь, разумеется, не исчерпывают всего многообразия возможностей, однако они часто выступают базой, с которой начинается обсуждение более сложных конструкций (в качестве примера приведём задачу аппроксимации нейросетями операторов в пространствах бесконечной размерности [37]). Ещё одним критерием для выбора данных примеров было продемонстрировать разнообразие постановок задач для методов машинного обучения. Далее перейдём к следующему этапу — численному решению задачи минимизации функции потерь.

2.3. Минимизация функции потерь

С одной стороны, задача поиска точки минимума функции является классической в численных методах, однако ряд особенностей, возникающих в контексте машинного обучения, формируют ряд новых вызовов как для методов, так и для вычислительных устройств. Пожалуй, первая особенность связана с высокой размерностью пространства, в котором ставится задача оптимизации. Современные нейронные сети имеют порядка $10^6 - 10^8$ параметров и обучаются на выборках сопоставимого размера. Соответственно, встаёт вопрос об эффективной параллелизации вычислений и использовании процессоров, поддерживающих такие технологии. В частности, используются графические процессоры (GPU) и специально разработанные для задач машинного обучения тензорные процессоры (TPU, см. [38]).

Другой важной особенностью задачи является то, что функция потерь почти всегда оказывается невыпуклой и имеет множество локальных минимумов. Соответственно, классический метод градиентного спуска оказывается неэффективным (приводит к ближайшему локальному минимуму, который может быть значительно хуже глобального) и, более того, результат будет сильно зависеть от выбора начальной точки (в контексте нейронных сетей говорят о начальной инициализации параметров модели, которая обычно задаётся случайным образом). Задачи машинного обучения стимулировали новый виток развития методов численной оптимизации, в результате появился ряд новых алгоритмов, использующих разные идеи того, как сойти в оптимальный локальный минимум. Обзор этих методов выходит за рамки статьи, приведём лишь некоторые алгоритмы, которые появились за последнее десятилетие и вошли в стандартный набор библиотек для работы с нейронными сетями:

- Adaptive Learning Rate Method (Adadelata, [39]);
- Adaptive Moment Estimation (Adam, [40]);
- Adaptive Subgradient method (Adagrad, [41]);
- Evolved Sign Momentum (Lion, [42]);
- Follow the Regularized Leader (FTRL, [43]).

Более классические алгоритмы, также входящие в стандартные библиотеки:

- Stochastic Gradient Descent (SGD, [44]);
- Averaged Stochastic Gradient Descent (ASGD, [45]);
- Limited Memory Broyden–Fletcher–Goldfarb–Shanno Algorithm (L-BFGS, [46]);
- Resilient Backpropagation (RPROP, [47]).




Рис. 4. Траектории поиска минимума, получаемые различными алгоритмами оптимизации: чёрная линия — Adam, оранжевая — SGD, сиреневая — RPROP. Красная точка показывает положение глобального минимума функции.

На рисунке 4 на примере одной и той же функции и начальной точки показаны траектории поиска минимума для некоторых алгоритмов.

Приведённые методы оптимизации используют в том или ином виде градиентный спуск. Встаёт вопрос о том, как вычислять производные (градиент) функции потерь по параметрам модели. Стандартные подходы — численное или символьное дифференцирование (компьютерная алгебра) — для таких целей не вполне подходят по ряду причин. Символьное дифференцирование работает медленно в силу особенностей реализации и оказывается неэффективным для глубоких сетей со сложной архитектурой. Численное дифференцирование в силу дискретной природы вносит ошибки, приводящие к неустойчивости, и оказывается неэффективным при большом числе параметров модели. Решением этих проблем стал метод, получивший название автоматического дифференцирования (Automatic Differentiation, см. [48] и современный обзор [49]). Обсудим одну из реализаций автоматического дифференцирования, получившую название алгоритма обратного распространения ошибки (Backpropagation, см., например, [50, 51] и современный обзор [52]) и являющуюся на сегодня основным методом при обучении нейронных сетей.

Вычислительный граф нейронной сети строится из узлов, представляющих собой простые арифметические операции: сумма, произведение, степень, экспонента, логарифм и т.д. В каждом узле, помимо прямой операции, записана функция, реализующая правило вычисления производной для этой операции. На примере простейшего вычислительного графа, показанного на рис. 5 и реализующего нейронную сеть с одним нейроном, поясним процедуру вычисления градиента по параметрам модели w и b .

Процедура состоит из двух этапов. На первом, называемом прямым проходом (forward-pass), проводится вычисление значений во всех узлах графа, от входного к




Рис. 5. Вычислительный граф для иллюстрации алгоритма обратного распространения ошибки. Зелёным показаны обучаемые параметры модели, синим — арифметические операции (умножение, сложение и вычисление нормы), оранжевым — остальные числовые переменные.

выходному, и сохранение их в памяти. Второй этап — обратный ход (backward-pass) — состоит в применении цепного правила дифференцирования сложной функции для последовательного нахождения производных при движении от выходного узла к узлам, содержащим параметры модели:

$$\frac{\partial l}{\partial b} = \frac{\partial l}{\partial z} \frac{\partial z}{\partial b}, \quad (10)$$

$$\frac{\partial l}{\partial w} = \frac{\partial l}{\partial z} \frac{\partial z}{\partial w}. \quad (11)$$

Правила вычисления всех производных в правой части (10) и (11) записаны в узлах графа: $\partial l / \partial z = 2(z - y)$, $\partial z / \partial b = 1$, $\partial z / \partial w = x$. Далее остаётся подставить значения x , y , z , сохранённые после прямого прохода. Отметим, что использование принципов динамического программирования позволяет избежать дублирования вычислений в (10) и (11) и даёт эффективную процедуру для более сложных архитектур нейронных сетей.

Далее запускается итеративная процедура обучения. На каждой итерации берётся подвыборка (в терминах машинного обучения она называется батч (batch)) из обучающего набора данных, вычисляется градиент функции потерь на этой подвыборке по параметрам модели и, в соответствии с алгоритмом оптимизации, обновляются параметры модели. Существуют разные критерии остановки итераций, например, когда значение функции потерь перестаёт значимо уменьшаться на обучающей выборке или пока не начала возрастать ошибка на валидационной выборке (математические рассуждения см., например, в [53]). Параметры модели на последней итерации фиксируются, и говорят, что получена обученная модель.

В следующем разделе рассмотрим примеры моделей и результатов их обучения в задачах физики Солнца.

3. Наборы данных для машинного обучения

Основой машинного обучения является обучающая выборка данных. Качество моделей зависит от свойств выборки:

- размер (количество объектов);
- вариативность (разнообразие примеров);
- несмещённость (статистические свойства обучающей выборки должны соответствовать свойствам тестовой выборки);
- точность аннотации (корректность классов, границ объектов и т.п.).

Важным фактором также является однородность формата данных. Например, если данные представлены изображениями и эти изображения имеют разный размер (в пикселях), то для эффективного (по времени) обучения моделей, скорее всего, потребуется приведение всех изображений к одному размеру. Например, эффективное обучение нейронных сетей основано на матричных операциях, соответственно, набор изображений должен быть представлен единым многомерным массивом.

На практике сбор и подготовка обучающего набора данных (датасета) — один из самых трудоёмких и

времязатратных этапов в машинном обучении, а также один из самых ресурсоёмких этапов, требующих больших хранилищ данных и большой скорости доступа (чтения/записи) к данным. В полной мере это может быть реализовано только в крупных вычислительных центрах. Всё перечисленное приводит к тому, что большие объёмы подготовленных для машинного обучения данных сегодня обладают исключительной ценностью. В таблице 1 собраны примеры источников данных о солнечной активности и наборов данных, подготовленных для задач машинного обучения. Отметим, что по-

Таблица 1. Пример каталогов солнечных наблюдений и баз данных, подготовленных для задач машинного обучения

Название	Краткое описание	Адрес	Ссылка на статью
НЕК	Сводная база данных из различных источников о событиях и объектах солнечной активности	https://lmsal.com/hek/	[54]
Helioviewer	Визуализация каталогов солнечных наблюдений с разных инструментов и карт солнечной активности	https://www.helioviewer.org/	[55]
Interactive Multi-Instrument Database of Solar Flares	Сводный каталог солнечных вспышек по данным GOES, RHESSI, SDO/AIA и ряда других инструментов за период 2002–2022 гг.	https://solarflare.njit.edu/	[56]
Catalogue of SDO/AIA 193 Angstrom synoptic maps and coronal holes	Каталог синоптических карт и карт корональных дыр по наблюдениям SDO/AIA в линии 193 Ангстрем с 2010 г. по н.в.	https://sun.njit.edu/coronal_holes	[57]
Large-Scale Dataset of Three-Dimensional Solar Magnetic Fields Extrapolated by Nonlinear Force-Free Method	Набор 73000 примеров реконструкций коронального магнитного поля над активными областями из каталога SHARP за период 2010–2019 гг.	https://nlfff.dataset.deepsolar.space/en	[58]
Large-scale Solar Dynamics Observatory image dataset for computer vision applications	Набор 260000 изображений SDO/AIA, отвечающих 270000 событиям из базы Heliophysics Event Knowledge Base (НЕК)	https://dataverse.harvard.edu/dataverse/lstdo	[59]
Machine Learning Data Set for NASA's Solar Dynamics Observatory	Откалиброванные и уменьшенные до разрешения 512×512 изображения SDO/AIA и SDO/HMI за период 2010–2018 гг.	2010 г., https://purl.stanford.edu/vk217bh4910 2011 г., https://purl.stanford.edu/jc488jb7715 2012 г., https://purl.stanford.edu/dc156hp0190 2013 г., https://purl.stanford.edu/km388vz4371 2014 г., https://purl.stanford.edu/sr325xz9271 2015 г., https://purl.stanford.edu/qw012qy2533 2016 г., https://purl.stanford.edu/vf806tr8954 2017 г., https://purl.stanford.edu/kp222tm1554 2018 г., https://purl.stanford.edu/nk828sc2920	[60]
ObserveTheSun	Каталог карт солнечной активности, составленный Кисловодской горной астрономической станцией	https://observethesun.ru	[61]
SDOBenchmark	Набор 8336 обучающих и тестовых 886 данных по солнечным вспышкам на основе изображений SDO/AIA и SDO/HMI за 12 ч, 5 ч, 1,5 ч и 10 мин до вспышки	https://i4ds.github.io/SDOBenchmark/	[62]
SEP ³	Сводный каталог СПС, КВМ, солнечных вспышек и их параметров по данным GOES, SOHO/LASCO, SDO/HMI и ряда других инструментов	https://sun.njit.edu/SEP3	[63]
SERPENTINE	Каталог данных по солнечным космическим лучам по наблюдениям Solar Orbiter, Parker Solar Probe, VepiColombo	https://serpentine-h2020.eu/	[64]
SHARP	Векторные магнитограммы активных областей и их параметры по наблюдениям SDO/HMI за период 2010–2020 гг.	http://jsoc.stanford.edu/doc/data/hmi/sharp/sharp.htm	[65]
SMARP	Магнитограммы активных областей по наблюдениям SOHO/MDI за период 1996–2010 гг.	http://jsoc.stanford.edu/	[66]

Таблица 1. Окончание

Название	Краткое описание	Адрес	Ссылка на статью
SOHO/EIT Flare Catalog	Каталог солнечных вспышек и их параметров по данным SOHO/EIT за период 1997–2010 гг.	https://doi.org/10.7910/DVN/C9H34R	[67]
Solar active region magnetogram image dataset for studies of space weather	Каталог магнитограмм активных областей, приведённых к единому размеру 600×600 пикселей (и 224×224 в уменьшенной версии) за период 2010–2018 гг.	Версия в полном разрешении https://doi.org/10.5061/dryad.dv41ns23n Версия в уменьшенном разрешении https://doi.org/10.5061/dryad.jq2bvq898	[68]
SolarMonitor	Визуализация каталогов солнечных наблюдений с разных инструментов и карт солнечной активности	https://www.solarmonitor.org/	[69]
SunInTime	Визуализация изображений солнечного диска со спутника SDO и каталога активных событий НЕК	https://suntoday.lmsal.com/	[54]
Sunspot groups	Каталог изображений групп солнечных пятен и их параметров по данным Кисловодской горной астрономической станции (ГАС ГАО РАН) за период 2010–2022 гг.	https://github.com/observethesun/sunspot_groups	[70]
SWAN-SF	Каталог солнечных вспышек и сопутствующих параметров, полученных в одно время с различными инструментами за период 2010–2018 гг.	https://doi.org/10.7910/DVN/EBCFKM	[71]

добные базы актуальны и для более общих задач изучения солнечной активности.

4. Программы для работы с данными

Использование методов машинного обучения предполагает применение инструментов как для создания и запуска моделей, так и для загрузки, предобработки данных и организации процедуры обучения. Инструменты для работы с моделями машинного обучения достаточно универсальны и не зависят от природы данных. Например, для работы с нейросетями популярными являются библиотеки PyTorch, Keras, Tensorflow. Инструменты обработки данных, напротив, существенно зависят от формата хранения данных и их природы. Поскольку в большинстве исследований по солнечной активности эти шаги достаточно стандартны и повторяются из одной работы в другую, имеет смысл не создавать программный код заново для каждой новой работы, а пользоваться едиными инструментами. Возни-

кает идея создания библиотек, ориентированных на решение стандартных задач обработки данных в определённой области исследований.

В солнечной физике одной из самых известных является библиотека SolarSoft [72], существующая уже более 30 лет. Написанная на языке IDL, она продолжает своё развитие и поддерживается в настоящее время. Большая часть её функционала сегодня реализована в библиотеке SunPy (табл. 2) на языке Python, который является основным для машинного обучения. Одновременно с этим появляется целый ряд других библиотек, решающих задачи создания однородных датасетов из различных источников наблюдательных данных, препроцессинга и анализа (см. примеры в табл. 2).

Отметим, что современной практикой является публикация исходного кода в открытых источниках (репозиториях). Это позволяет независимо верифицировать и воспроизводить этапы научного исследования и использовать его как отправную точку в дальнейших работах.

Таблица 2. Примеры библиотек программного кода для обработки и анализа солнечных наблюдений

Название	Краткое описание	Адрес
aiapy	Библиотека для калибровки и обработки данных SDO/AIA (см. [73])	https://aiapy.readthedocs.io/
FlareNet	Код для подготовки данных и обучения модели прогноза солнечных вспышек (см. [74])	https://github.com/nasa-fdl/flarenet
Mission ML Data Ready	Библиотека для создания датасетов из каталогов SOHO и SDO (см. [75])	https://github.com/cshneider/soho-ml-data-ready
observethesun	Коллекция программ и моделей по машинному обучению в физике Солнца	https://github.com/observethesun
SERPENTINE	Инструменты для загрузки и анализа данных по солнечным космическим лучам (см. [64])	https://serpentine-h2020.eu/
SunPy	Библиотека для загрузки, обработки и анализа наблюдательных данных по солнечной активности (см. [76])	https://sunpy.org/
SpaceML	Коллекция программ и моделей по машинному обучению в физике Солнца	https://spaceml.org/

5. Модели машинного обучения в физике Солнца

5.1. Сегментация изображений солнечного диска

Одним из основных видов наблюдательных данных о Солнце и солнечной активности являются изображения солнечного диска. Эти изображения могут быть получены в белом свете и на более специфических длинах волн. Обработку таких изображений наблюдатели начинают с выделения активных областей Солнца. Хорошо известным примером являются солнечные пятна, однако солнечная активность гораздо более разнообразна. В частности, существуют области, известные как корональные дыры. Они выглядят как тёмные области на снимках солнечного диска, сделанных в рентгеновском спектре (обычно берут линию 193 или 195 Å). Проблема в том, что не только корональные дыры, но и некоторые другие объекты также выглядят тёмными на подобных изображениях, например солнечные волокна. Таким образом, проблема идентификации (выделения контуров) корональных дыр не является тривиальной и однозначной.

С другой стороны, результаты многолетней обработки, собранные в каталоги карт корональных дыр, дают возможность создать модель машинного обучения, задачей которой было бы воспроизведение работы экспертов-наблюдателей. Недавно в работе [77] было предложено применить модель свёрточной нейронной сети типа U-Net [78] для сегментации корональных дыр.

Модель U-Net состоит из последовательности операций свёртки, применяемой к входному изображению солнечного диска. Пожалуй, наиболее известным примером свёртки является свёртка с гауссовым ядром, которое сглаживает изображение. Гауссово ядро содержит заранее заданные значения, в то время как в модели свёрточной нейронной сети значения ядра являются

обучаемыми параметрами. Обсудим преимущества такого подхода при работе с изображениями по сравнению с полносвязными моделями (например такой, как показана на рис. 2).

Во-первых, входом в полносвязную модель является вектор значений, но не матрица значений. Конечно, матрицу можно представить как вектор, но от этого теряется двумерная структура и понятие локальности (близкие пиксели изображения связаны между собой). Двумерная свёртка в данном случае выглядит более естественной моделью.

Вторая причина связана с количеством параметров модели. Представим, что входная матрица (изображение) имеет размеры 1000×1000 (характерное разрешение существующих снимков солнечного диска), и на следующем слое полносвязной сети будет хотя бы 100 нейронов. Тогда модель уже имеет порядка 10^8 параметров (число параметров имеет порядок произведения числа нейронов предыдущего слоя на число нейронов следующего). В свёрточной сети отдельное свёрточное ядро (обычно берут небольшие ядра, например, 3×3 , 5×5 , 7×7 , редко — больше) имеет число параметров порядка 10, и даже при использовании множества ядер удаётся получить меньшее общее число параметров.

Кроме того, свёрточная модель, в отличие от полносвязной, является инвариантной к сдвигам и до некоторой степени к размеру изображения. В самом деле, операция свёртки определена на изображениях любого размера, а сдвиг объектов на входном изображении приводит лишь к сдвигу на выходном. В полносвязной модели число входов фиксировано, а результат смещения объектов на входном изображении даёт плохо предсказуемый результат.

На рисунке 6 показаны некоторые из картинок, которые получаются после свёрток с набором ядер во внутренних слоях обученной модели U-Net. Отметим, что модель состоит из двух частей, работающих по принципу




Рис. 6. Архитектура свёрточной нейронной сети U-Net. Синие стрелки обозначают операции свёртки и понижения размера. Зелёные стрелки — транспонированная свёртка (свёртка и повышение размера). Оранжевые стрелки обозначают операцию стыковки массивов. Подписи под блоками обозначают размеры массивов (в терминах изображений — высота, ширина и число каналов). Картинки под схемой показывают отдельные срезы массивов, выделенных красными эллипсами.




Рис. 7. Сравнение результатов сегментации корональных дыр разными алгоритмами: (а) модель U-Net из работы [77], (б) алгоритм SPoCA [81], (в) алгоритм HIMERA [82]. (Рисунок из работы [77].)

энкодера и декодера. При прохождении через ветвь энкодера пространственные размеры изображения уменьшаются, но увеличивается число каналов. Полагается, что на данном пути из изображения извлекают признаки, значимые для решения целевой задачи. На ветви декодера признаки разворачиваются в новое изображение, и в случае задачи сегментации — это бинарная матрица, в которой единицы отвечают пикселям, принадлежащим искомым объектам (например, корональным дырам).

В работе [77] модель обучалась на многолетнем массиве карт корональных дыр Кисловодской горной астрономической станции Главной (Пулковской) астрономической обсерватории РАН (ГАС ГАО РАН). При обучении использовалась стандартная для задачи сегментации метрика — бинарная кросс-энтропия (напомним, такая же метрика стандартно используется для задачи классификации; задача сегментации рассматривается как задача попиксельной классификации).

На рисунке 7 приведён пример сегментации с помощью обученной модели U-Net в сравнении с некоторыми другими алгоритмами. Наблюдаемые, порой значимые, различия являются предметом продолжающихся дискуссий (см., например, [79, 80]), ясность в которых, вероятно, будет наступать по мере накопления опыта использования полученных данных. В связи с этим можно ещё раз отметить одну из принципиальных задач для машинного обучения: усвоить методологию экспертной обработки данных и воспроизвести её на новых (или наоборот, исторических) данных. Тем самым будет создан долговременный однородный ряд данных, актуальный для многих задач исследования физики Солнца.

Интересно отметить, что обсуждавшая выше особенность свёрточных моделей — независимость от размера входного изображения — нашла своё подтверждение в работе [57], в которой модель U-Net, обученная на изображениях солнечного диска, показала устойчивый результат при сегментации корональных дыр на синоптических картах (напомним, что синоптическая карта представляет собой склейку полной поверхности Солнца из ежедневных наблюдений солнечного диска).

Идея использования модели типа U-Net для сегментации изображений солнечного диска получила дальнейшее развитие: в работе [83] — для сегментации волокон, в работе [84] — активных областей на векторных магнитограммах, в работе [85] — областей в солнечной короне, в работе [86] — гранул на фотосфере.

Продолжается изучение различных архитектур: в работе [87] использовалась свёрточная модель, которая получала на вход набор изображений в разных спектральных линиях и магнитограмму и решала задачу сег-

ментации корональных дыр; авторы работы [88] рассмотрели задачу детекции (построения рамки вокруг объекта) на примере выделения корональных дыр, солнечных пятен и протуберанцев; в работах [89–91] рассматривалась более сложная задача сегментации, в которой, помимо классификации пикселей на те, что принадлежат искомому классу объектов и те, что не принадлежат, требуется ещё и разделять отдельные экземпляры внутри класса (так называемая задача instance segmentation, в отличие от более простой задачи semantic segmentation, рассмотренной выше).

5.2. Параметрическое описание данных

Следующим этапом после выделения активных областей обычно идёт замер их характеристик. Например, для группы солнечных пятен определяют площадь, протяжённость по широте и долготе, угол наклона к экватору и присваивают определённый морфологический класс, следуя, например, Цюрихской системе классификации (см. [92]). Иногда рассматривают более сложные топологические характеристики (см., например, [93]). Аналогичный анализ проводится и для других видов областей. Математически речь идёт о том, что объектам приписываются некоторые количественные характеристики. Вопрос о том, какие характеристики могут быть полезны, например, для изучения солнечной активности или прогноза факторов космической погоды, является открытым, и можно рассмотреть более общий вопрос о новых способах количественного описания объектов.

В работе [70] для описания структуры групп солнечных пятен было предложено использовать нейросетевую модель типа вариационного автоэнкодера. Общая архитектура модели представлена на рис. 8 и состоит из двух частей: энкодера и декодера. Стоит отметить, что у этой архитектуры много общего с архитектурой модели U-Net (см. рис. 6), обе модели используют понятие скрытого (латентного) пространства и основаны на идее сжатия и восстановления.

Для обучения использовался набор изображений групп солнечных пятен из каталога Кисловодской горной астрономической станции (www.observethesun.ru). Задачей модели на этапе обучения было подобрать такие функции энкодера и декодера, чтобы их композиция (т.е. сжатие и обратное восстановление) приводили к исходному образу. Дополнительно для ранжирования параметров, получаемых на выходе из энкодера, использовался метод главных компонент (Principal Component




Рис. 8. Архитектура вариационного автоэнкодера. Входное изображение проходит через последовательность свёрточных слоёв (энкодер), на выходе формируются два массива, которые интерпретируются как параметры нормального распределения. Случайный вектор из полученного распределения пропускается через вторую последовательность свёрточных слоёв (декодер), которая на выходе даёт восстановленное изображение. (Рисунок из работы [70].)




Рис. 9. Реконструкция изображений групп солнечных пятен при варьировании двух параметров (обозначенных как Z1 и Z5), кодирующих изображение. Из рисунка следует интерпретация: параметр Z1 кодирует униполярную или биполярную структуру группы, а параметр Z5 задаёт её наклон. (Рисунок из работы [70].)

Analysis, PCA). В результате была получена модель, преобразующая изображения групп солнечных пятен размером 256×256 пикселей в 283 числовых параметра. Далее был проведён анализ полученных параметров, чтобы дать им физическую интерпретацию. Для этого варьировался один или несколько параметров при фиксированных остальных и изучались восстановленные изображения. Пример полученных картинок показан на рис. 9, из которого был сделан вывод, что один из параметров характеризует общую биполярную или униполярную структуру группы, а второй отвечает за наклон группы (тилт-угол). В качестве приложения на основе полученных параметров была предложена модель оценки сложности и автоматической классификации групп солнечных пятен.

Идея исследования и использования признаков, полученных методами машинного обучения, возникает и в ряде других работ. Например, в работе [94] автоэнкодер применялся для описания профилей спектральных линий и также было показано, что полученные параметры допускают физическую интерпретацию, в частности, характеризуют асимметрию и ширину спектральной линии. В работе [95] модель автоэнкодера привлекалась для выделения аномальных изображений и локализации активных областей в сериях изображений солнечного диска, полученных со спутника SDO. А в работе [96] также на основе параметров, выделенных из изображений солнечного диска, была предложена модель генерации синтетических изображений и прогноза потока радиоизлучения. В недавней работе [97] было показано, что параметры магнитных активных областей, выделенные автоэнкодером, могут служить прекурсорами для солнечных вспышек и с их помощью удаётся повысить точность и заблаговременность прогноза.

Приведённые примеры из области солнечной физики, а также целый ряд аналогичных исследований в других

областях показывают, что методы машинного обучения открывают новую возможность для описания и анализа данных. Примечательно, что некоторые из параметров, выделяемых моделями, совпадают с теми, на которые в первую очередь обращают внимание эксперты, работающие с данными. И если эксперт приходит к выводу о важности некоторых параметров, руководствуясь многолетним опытом и знанием предметной области, то модель машинного обучения делает это лишь путём сбора статистики. Отметим также, что элементы такого подхода часто встречаются в моделях классификации, регрессии и прогноза, например, в качестве дополнительных параметров, на которых строится модель. В следующем разделе рассмотрим эти конструкции более подробно.

5.3. Прогноз солнечной активности

Задача прогноза параметров солнечной активности концентрирует в себе, пожалуй, все основные теоретические модели и наблюдательные данные. При этом многие механизмы остаются не вполне понятными и по факту заменяются на эмпирически (статистически) обнаруженные связи. Интерес к использованию методов машинного обучения обусловлен тем, что с помощью таких методов можно исследовать наличие связей в существенно более широком пространстве данных и, как следствие, получать, с одной стороны, более точные модели, а с другой — новые идеи для теоретических моделей.

Среди задач прогноза можно выделить две большие группы: прогноз "редких" событий и прогноз индексов. Обсудим возникающие в них особенности.

5.3.1. Прогноз редких событий. К этой задаче отнесём прогноз явлений, которые на фоне долговременной солнечной активности можно назвать редкими: например, солнечные вспышки (прежде всего, практический интерес представляет прогноз мощных вспышек классов M и X), корональные выбросы масс (КВМ), солнечные протонные события (СПС) и др. Стандартный приём состоит в том, что время дискретизируется (например, по дням), и задача сводится к бинарной классификации (есть или нет события в данный промежуток времени). В силу редкой природы событий количество примеров, когда событие было, оказывается существенно меньше, чем когда его не было, и выборка оказывается сильно несбалансированной (например, на одну область с X-вспышкой приходится 800 областей без вспышек, см. [98]). При попытке стандартного построения моделей прогноза на основе машинного обучения (или другого статистического метода) выясняется, что модели имеют тенденцию не обращать внимания на редкие события и сводятся к тривиальному решению — предсказанию преобладающего класса. Соответственно, необходимо использовать приёмы, повышающие значимость ошибки для редких событий, например, вводить весовые коэффициенты в функции потерь, искусственно балансировать выборку, выбирая равное количество положительных и отрицательных примеров, искусственно моделировать новые положительные примеры.

Другой особенностью, вытекающей из временной дискретизации моделей прогноза, является то, что не вполне ясно, как оценивать точность модели. Например, согласно прогнозу, событие должно наступить в

течение 24 ч, а по факту оно произошло через 24 ч и 1 мин. При стандартном обучении и тестировании модели такой случай будет оценён как ошибочный, хотя с интуитивной точки зрения модель была близка к правильному ответу. Похожие проблемы возникают с самим определением того, что считать событием, а что нет. Дело в том, что большинство из них по определению связано с некоторым условным порогом (например, энергия частиц больше 10 МэВ для событий типа СПС). В данном случае ложноположительный прогноз также может быть связан не с глобальной неточностью модели, а с близостью к пороговому значению). Может показаться, что такие нюансы как-то нивелируются на фоне большинства, однако здесь следует вспомнить, что общее число редких событий невелико, и на деле ошибка в отдельном событии может сказываться на всей модели. В связи с этим в работе часто используют не одну метрику (например, долю правильных предсказаний), а набор метрик, с разных сторон характеризующих прогностическую силу модели. И далеко не всегда одна модель, которая лучше другой по какой-то одной метрике, оказывается лучше сразу по всем. В качестве примера в табл. 3 приведён ряд метрик, часто встречающихся в статьях, посвящённых прогнозу событий солнечной активности. Чтобы не создавать путаницы, используются английские названия (русскоязычное название приводится там, где есть общепринятый эквивалент). Поскольку большинство метрик бинарной классификации вычисляется из матрицы ошибок, используются обозначения: TP (true positive) — количество верно предсказанных положительных классов (событие произошло), FP (false positive) — количество ложноположительных ответов, TN (true negative) — количество верно предсказанных отрицательных классов (события нет), FN (false negative) — количество ложноотрицательных ответов), $P = TP + FN$ — количество положительных классов в выборке, $N = TN + FP$ — количество отрицательных классов в выборке.

Отметим ещё один аспект, возникающий при оценке точности моделей. Дело в том, что понятия положительного или отрицательного прогноза для моделей типа логистической регрессии является пороговым: прогно-




Рис. 10. Примеры ROC-кривых для разных классификаторов. Каждая точка на кривой отвечает метрикам точности модели (чувствительность и 1–специфичность) для некоторого порога классификации, для построения кривой порог варьируется от нуля до единицы. Зелёная штриховая линия — модель чисто случайного прогноза. Красная кривая — модель, работающая лучше, чем случайная. Оранжевая кривая — модель, близкая к безошибочной. Синяя кривая — модель, дающая обратные предсказания (т.е. если интерпретировать её предсказания с точностью до наоборот, то получится хороший классификатор). Площадь под ROC-кривой называется метрикой ROC-AUC.

зом модели является число в интервале от 0 до 1 (интерпретируется как вероятность принадлежности данного объекта положительному классу), которое затем сравнивается со стандартным порогом 0,5 для принятия решения. При изменении порога будет изменяться матрица ошибок и, соответственно, производные от неё метрики. Например, при повышении порога будет уменьшаться ошибка I рода, но расти ошибка II рода. Для интегральной оценки влияния порога строят график в осях чувствительность против 1–специфичность варьированием порога от 0 до 1. Полученный график называют ROC-кривой (Receiver Operating Characteristic). В силу определения график получается неубывающим и

Таблица 3. Метрики бинарной классификации

Название	Определение	Смысл
Precision, точность	$\frac{TP}{TP + FP}$	Доля правильных ответов в положительных прогнозах
Accuracy	$\frac{TP + TN}{N}$	Доля правильных ответов
False positive rate (FPR), ошибка I рода	$\frac{FP}{N}$	Вероятность ложноположительного прогноза
False negative rate (FNR), ошибка II рода	$\frac{FN}{P}$	Вероятность ложноотрицательного прогноза
Sensitivity, recall, true positive rate (TPR), чувствительность	$\frac{TP}{P}$	Вероятность истинноположительного прогноза, 1–ошибка II рода
Specificity, selectivity, true negative rate (TNR), специфичность	$\frac{TN}{N}$	Вероятность истинноотрицательного прогноза, 1–ошибка I рода
F ₁ score	$2 \frac{\text{precision} \times \text{recall}}{\text{precision} + \text{recall}}$	Среднее гармоническое между precision и recall
True Skill Statistic (TSS)	$\frac{TP}{P} - \frac{FP}{N}$	1–ошибка I рода – ошибка II рода

соединяет начало координат с точкой (1,1). Площадь под графиком называется метрикой ROC-AUC (Area Under Curve), и для идеального классификатора она равна 1 (рис. 10). Метрика ROC-AUC имеет простую вероятностную интерпретацию: она равна вероятности того, что отклик модели на случайно выбранном примере из положительного класса будет выше, чем на случайно выбранном примере отрицательного класса.

При построении моделей прогноза активных событий обычно строятся модели прогноза для активной области — потенциальных источников солнечных вспышек, КВМ, СПС и других событий. Соответственно, возникает задача выделения активных областей, и от её решения будет зависеть точность прогноза. В контексте машинного обучения важно, чтобы модели строились на одной и той же выборке, в противном случае затрудняется сравнение моделей. Большой вклад в решение этой задачи был сделан в работе [63], в которой представлен алгоритм выделения и набор данных SHARP (Space-weather HMI Active Region Patches) активных областей и их параметров на векторных магнитограммах. В последующей работе [99] была представлена первая модель прогноза солнечных вспышек, использующая каталог SHARP и модель машинного обучения. Разнообразие последующих моделей и сопоставление результатов является темой для отдельного большого обзора. В частности, обзору моделей прогноза солнечных вспышек посвящён цикл работ [100–103], а также [104]. Недавно вышел обзор моделей прогноза солнечных протонных событий [105]. В обзоре представлено более 30 моделей прогноза СПС. Обсудим одну из них, основанную на модели нейронной сети, следуя оригинальной работе [106].

Модель прогноза СПС [106] агрегирует параметры магнитных активных областей из датасета SHARP, наблюдаемых в течение суток, и формирует прогноз наступления СПС на следующий день. Параметры активной области проходят через полносвязную нейронную сеть, кодирующую их в меньшее число переменных. Полученные с разных активных областей параметры стыкуются в один вектор, который пропускается через вторую полносвязную нейронную сеть с логистической




Рис. 11. Архитектура нейронной сети для прогноза СПС. Первая нейронная сеть (AR Block) кодирует параметры активной области. Полученные параметры с разных активных областей подаются на вход второй нейронной сети, формирующей прогноз. (Рисунок из работы [106].)




Рис. 12. Структура простейшей рекуррентной нейронной сети. Слева от серой стрелки показан компактный вид: новое внутреннее состояние h_{t+1} вычисляется на основе текущего h_t и наблюдаемого значения x_t ; выходное значение y_t является функцией от внутреннего состояния h_t ; U , V и W обозначают обучаемые параметры модели. Справа от серой стрелки показан развёрнутый вид вычисления последовательности внутренних состояний и выходных значений.

функцией активации (сигмоида) на выходном нейроне. Архитектура модели показана на рис. 11. При обучении нейронной сети дисбаланс выборки (1 к 34) учитывался тем, что положительные примеры многократно дублировались. Предложенная схема кодирования–агрегации–прогноз является достаточно общей и допускает множество вариаций. Например, кодировать можно не параметры активной области, а непосредственно изображение активной области, при агрегации использовать дополнительные параметры с других телескопов, а модель нейронной сети заменить на другие модели машинного обучения (см., например, [107]).

5.3.2. Прогноз индексов солнечной активности. В отличие от задачи прогноза редких событий, которая в стандартной постановке является задачей классификации, прогноз индексов солнечной активности (например, солнечного цикла, потоков рентгеновского излучения, K_p индекса геомагнитной активности) рассматривается в терминах временных рядов. Различие двух точек зрения состоит в том, что классификация является задачей интерполяции, а прогноз временного ряда — экстраполяцией. Это различие также проникает и в структуру моделей. Говоря о нейронных сетях, в первом случае чаще встречаются полносвязные и свёрточные сети, а во втором — рекуррентные (Recurrent Neural Network, RNN). Особенностью рекуррентных моделей является механизм памяти, позволяющий накапливать информацию при проходе по последовательности неограниченной длины. На рисунке 12 показан простейший пример рекуррентной нейронной сети, в которой для текущего наблюдаемого значения x_t внутреннее состояние h_t обновляется по правилу

$$h_t = f(Ux_t + Vh_{t-1}), \quad (12)$$

а выходное (прогнозное) значение y_t вычисляется как функция от внутреннего состояния

$$y_t = g(Wh_t), \quad (13)$$

где f , g — функции активации, а U , V и W — обучаемые параметры модели.

На практике применяются более сложные архитектуры, использующие понятие длинной и короткой памяти (Long Short-Term Memory, LSTM), анализирующие последовательность в обоих направлениях (bi-directional)




Рис. 13. Прогнозы интенсивности максимума 25-го солнечного цикла. (Рисунок из работы [110].)

и содержащие несколько уровней рекуррентных моделей (см. обзоры [108, 109]).

В работе [110] 2021 года (начало роста 25-го солнечного цикла) был представлен сравнительный график 34 прогнозов интенсивности 25-го солнечного цикла, из которого видна большая неопределённость прогноза в будущее, несмотря на то что все методы успешно прогнозировали прошлые циклы (рис. 13).

В рамках машинного обучения такую ситуацию можно попробовать объяснить следующим образом. Прогноз максимума следующего цикла можно получить, либо напрямую прогнозируя максимум, либо получая прогноз всего цикла, например рекуррентной моделью (рис. 14), и находя его максимум. В первом случае размер обучающей выборки равен не количеству лет наблюдений солнечных циклов, а всего лишь числу известных




Рис. 14. Прогноз на основе рекуррентной модели: x_t — последнее наблюдаемое значение временного ряда, прогноз вперёд строится на основе предыдущих прогнозных значений $\hat{x}_{t+k}$.

максимумов. Вследствие большой неопределённости исторических данных указанное число не превышает нескольких десятков. Во втором случае возникает известная проблема: как обеспечить устойчивость модели, которая при построении прогноза использует предыдущие прогнозные значения? Для этого можно обучать модель на длинном прогнозе (порядка длины цикла), но последнее вновь сужает эффективный объём обучающей выборки до размера порядка числа солнечных циклов, как и в первом случае. Таким образом, возникает сильно недоопределённая задача (объём обучающей выборки имеет размер нескольких десятков, а типичная модель нейронной сети имеет число свободных параметров на порядки больше), что приводит к большой неопределённости при прогнозе.

Тем не менее исследования возможностей прогноза солнечного цикла методами машинного обучения продолжают (см., например, недавние работы [111–113]), внося вклад в изучение фундаментальных вопросов природы солнечной цикличности (см. [114]).

Прогнозу индексов геомагнитной активности методами машинного обучения посвящены работы [115–120] и др.; прогнозу солнечного ветра — [121–123] и др. (о проблеме прогноза солнечного ветра см. обзор [124]). Отметим, что в этих исследованиях ставится задача короткого прогноза (несколько дней вперёд), что значительно повышает объём и вариативность обучающей выборки и позволяет рассчитывать на более устойчивый прогноз.

5.4. Реконструкция наблюдательных данных

Между различными явлениями солнечной активности существует тесная связь, в основе которой лежат солнечные магнитные поля [125]. Наличие этой внутренней

связи позволяет ставить задачу машинного обучения о преобразовании наблюдательных данных одного вида в другие. В качестве первого примера рассмотрим задачу реконструкции карт полярности крупномасштабного магнитного поля по наблюдениям солнечных волокон.

Полагается, что солнечные волокна (протуберанцы) формируются вдоль нейтральных линий магнитного поля Солнца. Зная положения волокон, можно оценить положение нейтральной линии и затем расставить знаки полярности так, чтобы по разные стороны нейтральной линии находились разные знаки. Более тонкие детали этого процесса были описаны в работе [126], однако даже с их учётом результат восстановления карт полярности оказывается неоднозначным, и основные каталоги карт полярностей создавались вручную на протяжении длительного времени [127–129]. Идея автоматического подхода, предложенная в недавней работе [130], основана на формулировке оптимизационной задачи и её решения путём подбора функции, заданной с помощью полносвязной нейронной сети. Карта полярности, заполненная знаками плюс и минус, рассматривается как поверхность гладкой функции, зависящей от гелиографических координат, где знак плюс отвечает значению функции +1, знак минус — значению –1, и вдоль нейтральной линии функция принимает значение 0. Оптимизационная задача строится из тех соображений, что координаты волокон задают координаты, в которых функция равна нулю, и ряда физических ограничений, не позволяющих сходиться к тривиальному (нулевому) решению. Выясняется, что решение такой оптимизационной задачи оказывается близко к карте полярности, построенной экспертом вручную (рис. 15).

Более тонкую структуру магнитного поля, например корональные магнитные поля, можно реконструировать на основе фотосферных наблюдений. Обычно для этого используют модель (систему уравнений) бессилового поля

$$\begin{aligned} \nabla \cdot \mathbf{B} &= 0, \\ \|(\nabla \times \mathbf{B}) \times \mathbf{B}\| &= 0 \end{aligned} \quad (14)$$

и фотосферные магнитограммы $\mathbf{B}_0(x, y)$ как граничные условия

$$\mathbf{B}(x, y, 0) = \mathbf{B}_0(x, y). \quad (15)$$




Рис. 15. Примеры реконструкции карт полярности магнитного поля для трёх синоптических оборотов (по строкам). (а) Синоптическая карта, задающая положения солнечных волокон. (б) Карта полярности, полученная экспертом [127]. (в) Усреднение по 100 реализациям нейросетевой модели реконструкции. (г) Бинаризованная версия рис. в. (Рисунок из работы [130].)




Рис. 16. Схема восстановления коронального магнитного поля над активной областью с помощью модели PINN. (Рисунок из работы [132].)

Численное решение этой задачи существенно осложняется тем, что наблюдательные данные не вполне согласуются с моделью бессилового поля [131] и возможное решение должно нарушать либо одно, либо другое условие. Возникшая ситуация вступает в противоречие со стандартными численными методами решения дифференциальных уравнений, однако может быть реализована в рамках модели физически информированных нейронных сетей (Physics-Informed Neural Networks, PINN). Напомним, идея состоит в том, что нейронная сеть задаёт функцию от пространственных координат, которая затем оптимизируется так, чтобы как можно ближе следовать дифференциальному уравнению и краевым условиям. В контексте восстановления коронального магнитного поля такая идея была продемонстрирована в работах [132, 133] (рис. 16). В работе [134] модель PINN применялась для моделирования распространения ударных волн в солнечной атмосфере.

Другим примером задачи реконструкции является перевод изображений диска Солнца, полученных в одной области спектра, в изображения из другой области спектра (image-to-image translation). В работе [60] была предложена модель свёрточной нейронной сети для реконструкции SDO/AIA изображений в УФ-диапазоне с использованием магнитограмм SDO/HMI. Решение обратной задачи было представлено в работе [135] с применением генеративной модели cGAN (см. пример на рис. 17). В качестве приложения авторы [135] представили магнитограммы дальней стороны Солнца на основе наблюдений STEREO/EUVI. Дальнейшее развитие методов перевода и новые комбинации изображений исследовались, например, в [136–139].

К этой же группе задач можно отнести и задачу повышения пространственного разрешения изображений и снижения шума. В работе [140] была сделана одна из первых попыток использования свёрточной нейронной сети. Модель обучалась на парах изображений с разным пространственным разрешением, полученных в процессе магнитогидродинамического (МГД) моделирования, а тестирование проводилось на реальных магнитограммах SDO/HMI (рис. 18). Дальнейшие исследования моделей на основе машинного обучения см., например, в работах [141–145].

Вопрос о достоверности получаемых реконструкций обсуждался в работе [146]. Авторы приходят к выводу, что, хотя статистически результаты оказываются весьма правдоподобными, в отношении редких и мощных событий качество реконструкции существенно снижается.

Особую актуальность проблема реконструкции приобретает при работе с историческими наблюдательными данными, которые хранятся в виде рукописных записей и




Рис. 17. Пример работы модели реконструкции магнитограммы SDO/HMI на основе изображения SDO/AIA солнечного диска в линии 304 Å. (а) Оригинальное изображение SDO/AIA, (б) результат реконструкции, (в) оригинальное изображение SDO/HMI. (Рисунок из работы [135].)

зарисовок. Использование таких данных для систематического анализа требует перевода в цифровой вид, и при работе с большими каталогами в этом может помочь машинное обучение. Например, в работе [147] была решена задача оцифровки более 10000 страниц с рукописными таблицами, задающими положения пятен, факелов и протуберанцев, из архива Цюрихской




Рис. 18. Пример работы модели повышения пространственного разрешения для магнитограммы SDO/HMI. Вверху слева — оригинальное изображение SDO/HMI, внизу справа — обработка моделью. (Рисунок из работы [140].)

10.5 -34.0 134.3 5.6 134.9 61.1	а	10.5 -34.0 134.3 5.6 134.9 61.1	б
-5.6 -68.5 168.8 -12.4 168.6 94.8		-5.6 -68.5 168.8 -12.4 168.6 94.8	
-14.8 -35.2 135.5 -19.8 134.0 60.2		-14.8 -35.2 135.5 -19.8 134.0 60.2	
-14.7 -33.0 133.3 -19.4 131.7 57.9		-14.7 -33.0 133.3 -19.4 131.7 57.9	
-18.0 -33.7 134.0 -22.8 132.1 58.3		-18.0 -33.7 134.0 -22.8 132.1 58.3	
-17.4 -31.0 131.3 -21.9 129.4 55.6		-17.4 -31.0 131.3 -21.9 129.4 55.6	
10.2 60.4 39.9 15.5 40.9 327.1		10.2 60.4 39.9 15.5 40.9 327.1	
11.0 9.8 90.5 10.9 91.9 18.1		11.0 9.8 90.5 10.9 91.9 18.1	
-15.7 -49.2 149.5 -21.7 148.3 74.5		-15.7 -49.2 149.5 -21.7 148.3 74.5	
45.6 -41.0 141.3 40.1 145.3 71.5		45.6 -41.0 141.3 40.1 145.3 71.5	
43.2 -38.7 139.0 37.8 142.7 68.9		43.2 -38.7 139.0 37.8 142.7 68.9	
47.2 -38.5 138.8 41.8 143.0 69.2		47.2 -38.5 138.8 41.8 143.0 69.2	
46.6 -32.5 132.8 41.6 137.4 63.6		46.6 -32.5 132.8 41.6 137.4 63.6	
28.8 -59.2 159.5 22.2 160.6 86.8		28.8 -59.2 159.5 22.2 160.6 86.8	
30.0 -53.8 154.1 23.7 155.6 81.8		30.0 -53.8 154.1 23.7 155.6 81.8	
27.0 -52.4 152.7 20.8 154.0 80.2		27.0 -52.4 152.7 20.8 154.0 80.2	
22.7 -55.4 155.7 16.3 156.7 82.9		22.7 -55.4 155.7 16.3 156.7 82.9	
18.8 -53.5 153.8 12.5 154.6 80.8		18.8 -53.5 153.8 12.5 154.6 80.8	
21.2 -51.2 151.5 15.0 152.7 78.9		21.2 -51.2 151.5 15.0 152.7 78.9	
23.6 -49.3 149.6 17.5 150.9 77.1		23.6 -49.3 149.6 17.5 150.9 77.1	

Рис. 19. Фрагмент страницы из каталога Цюрихской обсерватории (а) и результат оцифровки с помощью нейронной сети из работы [147] (б).

обсерватории. Основную трудность представляла большая вариативность почерков, так что модель, обученная на ограниченной (хотя и большой) подвыборке примеров, испытывала трудности при распознавании текста с нового почерка. Решением стал адаптивный подход, когда модель (свёрточно-рекуррентная нейронная сеть, CRNN) автоматически дообучалась на каждой новой странице, используя лишь тот факт, что числа в таблицах с координатами не совсем произвольны, а обладают некоторой зависимостью. Пример результата оцифровки показан на рис. 19.

Отметим, что адаптивный подход существенно расширяет возможности моделей машинного обучения. При классическом подходе модель обучается на некоторой выборке, состоящей из пар независимых и зависимых переменных (x_i , y_i), и затем в неизменном состоянии используется на новых данных (supervised learning). На практике, однако, в данных со временем могут проис-

ходить значимые статистические изменения, из-за чего падает качество модели. Опять же, стандартным решением является подготовка новой обучающей выборки и новое обучение модели. Однако это не всегда возможно: изменения могут происходить часто, а процесс подготовки обучающих данных обычно занимает длительное время. Более того, сам факт снижения качества моделей обычно виден не сразу, а спустя некоторое время. Поэтому сегодня развиваются подходы, в которых модели автоматически непрерывно корректируются с использованием методов самообучения (self-supervised learning). Рассмотрим лишь некоторые идеи, как из неразмеченной выборки (для которой отсутствуют целевые значения y_i) можно искусственно создавать обучающие пары (x_i, y_i) .

В качестве простейшего примера можно привести текст, из которого убирается одно слово, и задача модели — восполнить пробел. Убранное слово становится целевым значением. Обратный пример — восстановление контекста для данного слова в предложении. В этом случае окружение слова объявляется целевыми значениями. Аналогичный пример можно привести и для изображений: на изображении закрашивается некоторый фрагмент, и задача модели — по изображению с пропуском восстановить пропущенный фрагмент. Перевод цветного изображения в чёрно-белое и задача обратной раскраски, поворот изображения на заданный угол и задача определения угла поворота, разрезка изображения на кусочки и обратная сборка — также используются в качестве задач для self-supervised обучения.

По построению видно, что self-supervised модель решает не напрямую исходную задачу (которой могла быть, например, задача классификации изображений), а некоторую искусственную задачу. Смысл такой подмены — научить модель выделять содержательные внутренние свойства объектов, или, иными словами, построить для них отображение в новое признаковое пространство. На практике часто оказывается, что в новом признаковом пространстве исходная задача (например, классификация) решается значительно лучше, чем в исходном. Отметим, что на этом принципе построены современные языковые модели: сначала на большой выборке модель учится некоторым общим принципам, а затем полученная модель используется как основа для решения конкретных задач. Более подробный обзор методов и приложений self-supervised обучения см., например, в работах [148–151].

5.5. Моделирование динамических процессов

Наиболее детальная картина звёздного (солнечного) динамо [152] сегодня получается путём прямого численного моделирования уравнений магнитной гидродинамики. В силу специфики задачи такой подход требует исключительно большой вычислительной сетки, однако даже самые современные вычислительные комплексы способны обеспечить расчёт на сетке, размер которой на много порядков меньше той, что вытекает из теоретических оценок. Ввиду этой и целого ряда других проблем прямое моделирование остаётся одной из самых трудных задач. Обзор ключевых результатов в данном направлении приведён в работе [153].

Другой подход в теории динамо связан с выделением и изучением средних полей. С его помощью методами численного моделирования удаётся воспроизвести наиболее значимые закономерности крупномасштабных маг-




Рис. 20. Схема оценки начального приближения для метода Ньютона. Столбики обозначают вычислительную сетку в последовательные моменты времени. Решения на предыдущих временных шагах и решение на текущем временном шаге (синие столбики) используются для обучения модели, при этом текущее решение является целевым значением. Затем решения на предыдущих временных шагах вместе с решением на текущем временном шаге подаются на вход модели для прогноза решения на следующий шаг (зелёный столбик). Прогнозное значение используется в качестве начального приближения для метода Ньютона. (Рисунок из работы [156].)

нитных полей Солнца, такие как, например, магнитный цикл (правило полярности Хейла), баггерфляй-диаграммы и более тонкие эффекты. Подробный обзор достижений и ограничений теории динамо средних полей приведён в обзорных работах [154, 155].

Методы машинного обучения только начинают вовлекаться в задачи численного моделирования, однако уже наметились некоторые направления. Одно из них связано с ускорением расчётов в классических численных схемах. Например, в недавней работе [156] предложен способ оценки начального приближения в методе Ньютона (метод касательных для нахождения корня заданной функции), позволяющий сократить число итераций нелинейного солвера. Идея основана на том, что алгоритм машинного обучения использует результаты предыдущих расчётных шагов для оценки решения на текущем шаге и эта оценка используется в качестве начального приближения (рис. 20). Особенностью метода является то, что он не использует предварительно обученных моделей, а оптимизируется непосредственно в процессе расчёта. Результаты показывают, что на некоторых примерах предложенный метод позволяет уменьшать общее время расчёта на 20 %. Хотя тестирование проводилось на задаче из гидродинамики, вполне можно предположить, что эффект ускорения расчёта может быть достигнут и в задачах МГД.

Другой пример использования машинного обучения — замыкание системы уравнения для совместного описания крупных и мелких (подсеточных) масштабов при моделировании турбулентности. В работе [157] для этого применялся подход на основе нейро-дифференциальных уравнений. Напомним, суть подхода состоит в том, что неизвестная функция в правой части дифференциального уравнения параметризуется с помощью нейронной сети, запускается расчёт динамики по стандартной численной схеме, далее нейронная сеть оптимизируется так, чтобы получаемое решение обладало нужными свойствами (например, совпадало с динамикой, доступной из наблюдений или смоделированной другими методами).

Задача полной замены "классического" численного солвера на модель машинного обучения при моделировании турбулентности изучалась, например, в работах [158, 159]. В частности, авторы использовали модели нейронного оператора [160] и нейронного фурье-оператора [161], суть которых состоит в следующем. Рассмотрим уравнение в области $D \subset \mathbb{R}^d$, заданное дифференциальным оператором $\mathcal{L}$:

$$\begin{aligned} (\mathcal{L}u)(x) &= f(x), \quad x \in D, \\ u(x) &= 0, \quad x \in \partial D, \end{aligned} \quad (16)$$

где a — коэффициенты уравнения (функции от x , в том числе скаляры), правая часть f — фиксированная функция. Классический подход к решению строится на разбиении пространства на ячейки, использовании разностных схем для аппроксимации уравнений и решении возникающей линейной системы. Идея нейронного оператора — в поиске ядра k интегрального оператора, который отображает пару (a, f) в решение системы u :

$$u(x) = \int_D k(x, y, a(x), a(y)) f(y) dy. \quad (17)$$

Можно заметить, что искомое ядро является функцией Грина — обратным оператором для $\mathcal{L}_a$. Его можно задать (аппроксимировать) с помощью, например, полносвязной нейронной сети. Для оптимизации нейронной сети используется выборка $\{a_i, u_i\}_{i=1}^n$ решений задачи (16) для различных коэффициентов a . Целевые решения u_i могут быть получены классическим солвером или быть известны из наблюдательных (экспериментальных) данных. Построенный оператор далее используется для оценки решения задачи (16) для новых значений a . Основное преимущество — скорость решения задачи, которая может быть значительно выше, чем в случае решения по классическим схемам.

Сопоставим классический численный подход и решение на основе машинного обучения. Преимущество первого подхода в том, что он позволяет получать решение при любых допустимых значениях управляющих параметров, обладает гарантиями на точность, приводит к физически согласованному решению. Основным недостатком является скорость решения при использовании мелкой сетки. Решение, основанное на машинном обучении (нейросетевом операторе), с одной стороны, на порядки быстрее, однако модель требует предварительного обучения и время на такое обучение (прежде всего, создание обучающей выборки) оказывается существенным. Кроме того, полученную модель имеет смысл применять только в том диапазоне параметров уравнения, из которого брались обучающие примеры. Точность получаемого решения трудно контролировать заранее (теория позволяет говорить лишь о точности в пределе бесконечно растущей выборки), и нет гарантий на физическую согласованность решения. Несмотря на, казалось бы, внушительный список "недостатков", с практической стороны скорость иногда оказывается решающим фактором. Например, этот инструмент может быть полезен, когда необходимо промоделировать большое число сценариев для предварительной оценки статистических свойств или выбора некоторых сценариев, полезных для дальнейшей работы. В подобных ситуациях быстрое, но не вполне точное решение может быть практичнее, чем долгое, но точное.

Более подробный обзор и варианты реализации нейросетевых операторов представлены в обзорах [162, 163], а обзор приложений и методов машинного обучения в более широком круге задач физики плазмы — в работе [164].

6. Заключение

Методы машинного обучения сформировали новое направление в исследованиях по солнечной физике. Его ключевыми составляющими являются:

- большие наборы данных,
- инструменты обработки данных,
- модели машинного обучения.

Одним из первых важных эффектов нового направления, оказавшим влияние на всю область исследования в целом, стало появление больших и однородных наборов данных (датасетов), подготовленных для проведения статистических исследований. Последнее позволило перенаправить время и усилия, которые раньше уходили на подготовку данных, на их непосредственный анализ и, как следствие, стимулировало рост числа публикаций. Это также сделало сравнимыми результаты независимых исследований и дало основу для их воспроизведения, что является важнейшими характеристиками научного исследования. Большие данные стали самостоятельной ценностью в физике Солнца в частности и в науке в целом.

Вторым значимым эффектом стало развитие базовых инструментов работы с данными и их публикация в открытом доступе. Это приводит к унификации процедур подготовки данных и, как результат, — к воспроизводимости исследования.

В-третьих, модели машинного обучения позволили математически сформулировать и исследовать задачи, которые ранее оставались плохо формализованными. Например, вопрос о том, где проходит граница солнечного пятна, на протяжении 400 лет наблюдений решался каждым наблюдателем индивидуально. Методы машинного обучения позволяют ставить задачу о воспроизведении конкретной методики обработки данных и её распространении на более длинные ряды данных.

Во многом изменился формат исследований в физике Солнца. Исследования становятся междисциплинарными — на стыке физической науки и вычислительных технологий. В работу вовлекаются физики-теоретики, специалисты по машинному обучению, специалисты по вычислительной инфраструктуре. Местом проведения исследований становятся крупные вычислительные центры.

Исследование приложений методов машинного обучения сегодня ведётся практически во всех областях физики Солнца. Обсуждению результатов посвящены специализированные конференции, ведущие журналы по физике Солнца выделяют статьи по методам машинного обучения в тематические выпуски, публикуются обзоры (например, [165, 166]) и книги, например:

- Е. Camporeale и др. *Machine Learning Techniques for Space Weather* [167],
- М. Bobra, J. Mason *Machine Learning, Statistics, and Data Mining for Heliophysics* [168],
- L. Xu и др. *Deep Learning in Solar Astronomy* [169].

Машинное обучение является новым инструментом исследования, однако роль исследователя при этом остаётся первостепенной. Модели, основанные на машинном

обучении, выглядят перспективными помощниками в прикладных задачах, когда требуется скорость обработки больших и/или многомерных данных и поддержание заданной методологии. В рамках развития общей теории модели машинного обучения могут использоваться для описания связей, которые пока не покрыты теорией, и последующего математического моделирования.

Современные и перспективные задачи, которые ставятся перед машинным обучением, характеризуются масштабом задействованных данных, сложностью моделей и процедур обучения. Как и в любой науке, выход на такой уровень не происходит одномоментно, а требует многолетней практики, опыта и современной технологической базы. В нашей стране есть все составляющие для подобных исследований, и требуется лишь поддержание систематической работы, чтобы оставаться на передовом крае развития физики Солнца.

Список литературы

- Марковъ А А "Примѣръ статистическаго изслѣдованія надъ текстомъ "Евгенія Онѣгина", иллюстрирующій связь испытаній въ цѣль" *Изв. Императорской акад. наукъ* **7** (3) 153 (1913)
- Vaswani A et al., arXiv:1706.03762
- Devlin J et al., arXiv:1810.04805
- Brown T B et al., arXiv:2005.14165
- Dosovitskiy A et al., arXiv:2010.11929
- Yan W et al., arXiv:2104.10157
- Lin T et al., arXiv:2106.04554
- Bommasani R et al., arXiv:2108.07258
- Vokhmyanin M, Arlt R, Zolotova N *Solar Phys.* **295** (3) 39 (2020)
- Rimmele T R et al. *Solar Phys.* **295** (12) 172 (2020)
- Clette F et al. *Solar Phys.* **298** (3) 44 (2023)
- Lemen J R et al. *Solar Phys.* **275** (1–2) 17 (2012)
- Колмогоров А Н *ДАН СССР* **108** 179 (1956)
- Liu Z et al., arXiv:2404.19756
- Cybenko G *Math. Control Signals Syst.* **2** 303 (1989)
- Hornik K, Stinchcombe M, White H *Neural Networks* **2** (5) 359 (1989)
- Funahashi K-I *Neural Networks* **2** (3) 183 (1989)
- Pinkus A *Acta Numerica* **8** 143 (1999)
- DeVore R, Hanin B, Petrova G *Acta Numerica* **30** 327 (2021)
- Murphy K P *Machine Learning: A Probabilistic Perspective* (Cambridge, MA: MIT Press, 2021)
- Bishop C M *Pattern Recognition and Machine Learning* (Information Science and Statistics) (New York: Springer-Verlag, 2006)
- Hastie T, Tibshirani R, Friedman J *The Elements of Statistical Learning: Data Mining, Inference, and Prediction* (Springer Series in Statistics) (New York: Springer, 2009) <https://doi.org/10.1007/978-0-387-84858-7>
- Johnson J, Alahi A, Fei-Fei L, arXiv:1603.08155
- Бахвалов Н С, Жидков Н П, Кобельков Г М *Численные методы* (М.: Наука, 1987)
- Raissi M, Perdikaris P, Karniadakis G E J. *Comput. Phys.* **378** 686 (2019)
- Goodfellow I, Bengio Y, Courville A *Deep Learning* (Cambridge, MA: MIT Press, 2016)
- Chen R T Q et al., arXiv:1806.07366
- Понтрягин Л С и др. *Математическая теория оптимальных процессов* (М.: Физматгиз, 1961); Пер. на англ. яз.: Pontryagin L S et al. *The Mathematical Theory of Optimal Processes* (New York: Interscience Publ., 1962)
- Pearson K *Philos. Mag.* **2** (11) 559 (1901)
- Johnstone I M, Paul D *Proc. IEEE* **106** 1277 (2018)
- Kingma D P, Welling M, arXiv:1312.6114
- Kingma D P, Welling M *Found. Trends Machine Learn.* **12** (4) 307 (2019)
- Rezende D, Mohamed Sh, in *Proc. of the 32nd Intern. Conf. on Machine Learning, Lille, France, 7–9 Jul 2015* (Proc. of Machine Learning Research, Vol. 37, Eds F Bach, D Blei) (MLR Press, 2015) p. 1530
- Kobyzev I, Prince S J D, Brubaker M A *IEEE Trans. Pattern Analysis Machine Intelligence* **43** 3964 (2021)
- Goodfellow I J et al., arXiv:1406.2661
- Arjovsky M, Chintala S, Bottou L, arXiv:1701.07875
- Kovachki N et al., arXiv:2108.08481
- Jouppi N P et al., arXiv:1704.04760
- Zeiler M D, arXiv:1212.5701
- Kingma D P, Ba J, arXiv:1412.6980
- Duchi J, Hazan E, Singer Y J. *Machine Learning Res.* **12** 2121 (2011)
- Chen X et al., arXiv:2302.06675
- McMahan B, in *Proc. of the Fourteenth Intern. Conf. on Artificial Intelligence and Statistics* (Proc. of Machine Learning Research, Vol. 15, Eds G Gordon, D Dunson, M Dudík) (MLR Press, 2011) p. 525
- Bottou L, in *On-Line Learning in Neural Networks* (Ed. D Saad) (Cambridge: Cambridge Univ. Press, 1999) p. 9, <https://doi.org/10.1017/CBO9780511569920.003>
- Polyak B T, Juditsky A B *SIAM J. Control Optim.* **30** 838 (1992)
- Zhu C et al. *ACM Trans. Math. Software* **23** 550 (1997)
- Riedmiller M, Braun H, in *IEEE Intern. Conf. on Neural Networks, 28 March 1993–01 April 1993, San Francisco, CA, USA* (Piscataway, NJ: IEEE, 1993) p. 586, <https://doi.org/10.1109/ICNN.1993.298623>
- Rall L B (Ed.) *Automatic Differentiation: Techniques and Applications* (Lecture Notes in Computer Science, Vol. 120) (Berlin: Springer-Verlag, 1981) <https://doi.org/10.1007/3-540-10861-0>
- Baydin A G et al. *J. Machine Learning Res.* **18** (153) 1 (2018)
- Rumelhart D E, Hinton G E, Williams R J *Nature* **323** 533 (1986)
- Hecht-Nielsen R, in *Intern. 1989 Joint Conf. on Neural Networks, IJCNN, Washington DC, 18–22 June 1989 Vol. 1* (Piscataway, NJ: IEEE, 1989) p. 593, <https://doi.org/10.1109/IJCNN.1989.118638>
- Schmidhuber J *Neural Networks* **61** 85 (2015)
- Yao Y, Rosasco L, Caponnetto A *Constr. Approx.* **26** 289 (2007)
- Hurlburt N et al. *Solar Phys.* **275** 67 (2012)
- Müller D et al. *Astron. Astrophys.* **606** A10 (2017)
- Sadykov V M et al. *Astrophys. J. Suppl.* **231** (1) 6 (2017)
- Illarionov E, Kosovichev A, Tlatov A *Astrophys. J.* **903** 115 (2020)
- Zhao Z et al. *Sci. Data* **10** 178 (2023)
- Kucuk A, Banda J M, Angryk R A *Sci. Data* **4** 170096 (2017)
- Galvez R et al. *Astrophys. J. Suppl.* **242** (1) 7 (2019)
- Илларионов Е А, Тлатов А Г *Изв. Крымской астрофиз. обсерватории* **114** (1) 118 (2018)
- Bolzern R, Aerni M "A machine learning image dataset for the prediction of solar flares" (2024)
- Kosovichev A G et al., in *AGU Fall Meeting 2023, San Francisco, CA, 11–15 December 2023*, id. SH33C-307, Poster No. 307
- Palmroos C et al. *Front. Astron. Space Sci.* **9** 395 (2022)
- Bobra M G et al. *Solar Phys.* **289** 3549 (2014)
- Bobra M G et al. *Astrophys. J. Suppl.* **256** 26 (2021)
- Rotti S A, Martens P C H, Aydin B *Astrophys. J. Suppl.* **249** (2) 20 (2020)
- Boucheron L E et al. *Sci. Data* **10** 825 (2023)
- Gallagher P T, Moon Y-J, Wang H *Solar Phys.* **209** 171 (2002)
- Illarionov E, Tlatov A *Solar Phys.* **297** (2) 19 (2022)
- Angryk R A et al. *Sci. Data* **7** (1) 227 (2020)
- Freeland S L, Handy B N *Solar Phys.* **182** (2) 497 (1998)
- Barnes W T et al. *J. Open Source Software* **5** (55) 2801 (2020)
- McGregor S et al., in *Workshop on Deep Learning for Physical Sciences, DLPS 2017, NIPS 2017, Long Beach, CA, USA, 2017*
- Shneider C et al., arXiv:2108.06394
- The SunPy Community, Barnes W T et al. *Astrophys. J.* **890** 68 (2020)
- Illarionov E A, Tlatov A G *Mon. Not. R. Astron. Soc.* **481** 5014 (2018)
- Ronneberger O, Fischer P, Brox T, in *Medical Image Computing and Computer-Assisted Intervention — MICCAI 2015. 18th Intern. Conf., Munich, Germany, October 5–9, 2015, Proc. Pt. 3* (Lecture Notes in Computer Science, Vol. 9351, Eds N Navab et al.) (Cham: Springer, 2015) p. 234, https://doi.org/10.1007/978-3-319-24574-4_28; arXiv:1505.04597
- Reiss M A et al. *Astrophys. J.* **913** 28 (2021)
- Reiss M A et al. *Astrophys. J. Suppl.* **271** 6 (2024)
- Verbeeck C et al. *Astron. Astrophys.* **561** A29 (2014)
- Garton T M, Gallagher P T, Murray S A J. *Space Weather Space Clim.* **8** A02 (2018) <https://doi.org/10.1051/swsc/2017039>
- Zhu G et al. *Solar Phys.* **294** 117 (2019)
- Jiang H et al. *Astrophys. J. Suppl.* **250** 5 (2020)
- Mackovjak Š et al. *Mon. Not. R. Astron. Soc.* **508** 3111 (2021)
- Diaz Castillo S M et al. *Front. Astron. Space Sci.* **9** 896632 (2022)
- Jarolim R et al. *Astron. Astrophys.* **652** A13 (2021)
- Baek J-H et al. *Solar Phys.* **296** 160 (2021)
- Ahmadzadeh A et al., arXiv:1912.02743
- Guo X et al. *Solar Phys.* **297** 104 (2022)

91. Diercke A et al. *Astron. Astrophys.* **686** A213 (2024)
92. McIntosh P S *Solar Phys.* **125** 251 (1990)
93. Макаренко Н Г, Князева И С, Каримова Л М *Письма в Астрон. журн.* **38** 597 (2012); Makarenko N G, Knyazeva N G, Karimova L M *Astron. Lett.* **38** 531 (2012)
94. Sadykov V M et al., in *2021 Intern. Conf. on Content-Based Multimedia Indexing CBMI, 28–30 June 2021, Lille, France* (Piscataway, NJ: IEEE, 2021) p. 1, <https://doi.org/10.1109/CBMI50038.2021.9461879>
95. Giger M, Csillaghy A *Space Weather* **22** e2023SW003516 (2024)
96. Brown E et al. "Learning the solar latent space: sigma-variational autoencoders for multiple channel solar imaging", in *Fourth Workshop on Machine Learning and the Physical Sciences, NeurIPS 2021*
97. Wang J et al. *Front. Astron. Space Sci.* **10** 1082737 (2023) <https://doi.org/10.3389/fspas.2023.1082737>
98. Ahmadzadeh A et al. *Astrophys. J. Suppl.* **254** 23 (2021)
99. Bobra M G, Couvidat S *Astrophys. J.* **798** 135 (2015)
100. Barnes G et al. *Astrophys. J.* **829** 89 (2016)
101. Leka K D et al. *Astrophys. J. Suppl.* **243** 36 (2019)
102. Leka K D et al. *Astrophys. J.* **881** 101 (2019)
103. Park S-H et al. *Astrophys. J.* **890** 124 (2020)
104. Georgoulis M K et al. *J. Space Weather Space Clim.* **11** 39 (2021)
105. Whitman K et al. *Adv. Space Res.* **72** 5161 (2023)
106. Sadykov V et al., arXiv:2107.03911
107. Ali A et al. *Astrophys. J. Suppl.* **270** 15 (2024)
108. Lipton Z C, Berkowitz J, Elkan C, arXiv:1506.00019
109. Sherstinsky A *Physica D* **404** 132306 (2020)
110. Nandy D *Solar Phys.* **296** 54 (2021)
111. Wang Q-J, Li J-C, Guo L-Q *Res. Astron. Astrophys.* **21** (1) 012 (2021)
112. Bizzarri I et al. *Mon. Not. R. Astron. Soc.* **515** 5062 (2022)
113. Prasad A et al. *Solar Phys.* **298** 50 (2023)
114. Обридко В Н, Наговицын Ю А *Солнечная активность, цикличность и методы прогноза* (СПб.: ВВМ, 2017)
115. Myagkova I, Shiroky V, Dolenko S *E3S Web Conf.* **20** 02011 (2017)
116. Ефиторов А О и др. *Космические исследования* **56** 420 (2018); Efitorov A O et al. *Cosmic Res.* **56** 434 (2018)
117. Тлатов А Г, Илларионов Е А, Березин И А, Шрамко А Д *Космические исследования* **58** 479 (2020); Tlatov A G, Illarionov E A, Berezin I A, Shramko A D *Cosmic Res.* **58** 444 (2020)
118. Bernoux G et al. *J. Geophys. Res. Space Phys.* **127** e2022JA030868 (2022)
119. Владимиров Р Д и др. *Геомагнетизм и аэронавтика* **63** (2) 190 (2023)
120. Telloni D et al. *Astrophys. J.* **952** 111 (2023)
121. Upendran V et al. *Space Weather* **18** (9) e02478 (2020) <https://doi.org/10.1029/2020SW002478>
122. Brown E J E et al. *Space Weather* **20** (3) e2021SW002976 (2022)
123. Son J et al. *Astrophys. J. Suppl.* **267** 45 (2023)
124. Петрукович А А и др. *УФН* **190** 859 (2020); Petrukovich A A et al. *Phys. Usp.* **63** 801 (2020)
125. Витинский Ю И *Солнечная активность* (М.: Наука, 1983)
126. McIntosh P S, in *Solar Activity Observations and Predictions* (Progress in Astronautics and Aeronautics, Vol. 30, Eds P S McIntosh, M Dryer) (Cambridge, MA: MIT Press, 1972) p. 65; Пер. на русск. яз.: Мак-Интош П, в сб.: *Наблюдения и прогноз солнечной активности* (Под ред. П Мак-Интоша, М Драйера) (М.: Мир, 1976)
127. McIntosh P S "Synoptic maps composites observed from McIntosh" (1964) <https://doi.org/10.7289/V5765CCQ>
128. Makarov V I, Fatianov M P, Sivaraman K R *Solar Phys.* **85** 215 (1983)
129. Makarov V I, Sivaraman K R *Solar Phys.* **85** 227 (1983)
130. Kisielius V, Illarionov E *Solar Phys.* **299** (5) 69 (2024)
131. Metcalf T R et al. *Astrophys. J.* **439** 474 (1995)
132. Jarolim R et al. *Nat. Astron.* **7** 1171 (2023)
133. Baty H, Vigon V *Mon. Not. R. Astron. Soc.* **527** 2575 (2024)
134. Moschou S P et al. *Machine Learn. Sci. Technol.* **4** 035032 (2023)
135. Kim T et al. *Nat. Astron.* **3** 397 (2019)
136. Park E et al. *Astrophys. J. Lett.* **884** L23 (2019)
137. Son J et al. *Astrophys. J.* **920** 101 (2021)
138. Jeong H-J et al. *Astrophys. J. Suppl.* **262** (2) 50 (2022)
139. Lawrance B et al. *Astrophys. J.* **937** (2) 111 (2022)
140. Diaz Baso C J, Asensio Ramos A *Astron. Astrophys.* **614** A5 (2018)
141. Diaz Baso C J, de la Cruz Rodriguez J, Danilovic S *Astron. Astrophys.* **629** A99 (2019)
142. Rahman S et al. *Astrophys. J. Lett.* **897** L32 (2020)
143. Xu C et al. *Solar Phys.* **299** 36 (2024)
144. Muñoz-Jaramillo A et al. *Astrophys. J. Suppl.* **271** 46 (2024)
145. Song W et al. *Astron. Astrophys.* **686** A272 (2024)
146. Salvatelli V et al. *Astrophys. J.* **937** 100 (2022)
147. Illarionov E, Arlt R *Solar Phys.* **297** 79 (2022)
148. Rani V et al. *Arch. Computat. Methods Eng.* **30** 2761 (2023)
149. Huang S-C et al. *npj Digit. Med.* **6** 74 (2023)
150. Shwartz Ziv R, LeCun Y *Entropy* **26** (3) 252 (2024)
151. Zhao Z et al. *Expert Syst. Appl.* **242** 122807 (2024)
152. Соколов Д Д *УФН* **185** 643 (2015); Sokoloff D D *Phys. Usp.* **58** 601 (2015)
153. Kápylä P J et al. *Space Sci. Rev.* **219** 58 (2023)
154. Brandenburg A, Sokoloff D, Subramanian K *Space Sci. Rev.* **169** 123 (2012)
155. Brandenburg A et al. *Space Sci. Rev.* **219** 55 (2023)
156. Petrosyants M, Trifonov V, Illarionov E, Koroteev D *Comput. Geosci.* **28** 605 (2024) <https://doi.org/10.1007/s10596-024-10284-z>
157. Williams J, Wolfram U, Ozel A *Phys. Fluids* **34** 113315 (2022)
158. Peng W, Yuan Z, Wang J *Phys. Fluids* **34** 025111 (2022)
159. Rosofsky S G, Huerta E A *Mach. Learn. Sci. Technol.* **4** 035002 (2023)
160. Lu L, Jin P, Karniadakis G E *Nat. Mach. Intell.* **3** 218 (2021); arXiv:1910.03193
161. Li Z et al., arXiv:2010.08895
162. Kovachki N et al. *J. Mach. Learn. Res.* **24** (89) 1 (2023)
163. Azzadenesheli K et al. *Nat. Rev. Phys.* **6** 320 (2024)
164. Anirudh R et al. *IEEE Trans. Plasma Sci.* **51** 1750 (2023)
165. Asensio Ramos A et al. *Living Rev. Solar Phys.* **20** 4 (2023)
166. Илларионов Е А, Садыков В М *Земля и Вселенная* (4) 35 (2021)
167. Camporeale E, Wing S, Johnson J R (Eds) *Machine Learning Techniques for Space Weather* (Cambridge, MA: Elsevier, 2018)
168. Bobra M G, Mason J P "Machine Learning, Statistics, and Data Mining for Heliophysics" (2020)
169. Xu L, Yan Y, Huang X *Deep Learning in Solar Astronomy* (SpringerBriefs in Computer Science) 1st ed. (Singapore: Springer, 2022) <https://doi.org/10.1007/978-981-19-2746-1>

Machine learning methods in solar physics

E.A. Illarionov

Lomonosov Moscow State University, Faculty of Mechanics and Mathematics, Leninskie gory 1, 119991 Moscow, Russian Federation
E-mail: egor.illarionov@math.msu.ru

The development of machine learning methods and their success in a wide range of problems have had a significant impact on the design and implementation of solar physics research. Large data sets have emerged as an intrinsic value in which the efforts of experts and significant technological resources are invested. The research itself has acquired an interdisciplinary nature and is concentrated around advanced computing centers. Large-scale problems can now be posed whose mathematical formulation was unclear yesterday. In this review, we present the main ideas underlying modern machine learning models, the databases prepared for machine learning tasks, and data processing tools. A major part of this review is devoted to a discussion of models proposed in the context of specific solar physics problems and their extension to other applications.

Keywords: solar physics, solar activity, machine learning, databases

PACS numbers: 07.05.Mh, **84.35.+i**, **96.60.-j**

Bibliography — 169 references

Uspekhi Fizicheskikh Nauk **195** (4) 395–415 (2025)

DOI: <https://doi.org/10.3367/UFNr.2025.02.039872>

Received 5 August 2024

Physics – Uspekhi **68** (4) (2025)

DOI: <https://doi.org/10.3367/UFNe.2025.02.039872>