

ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ: ОБЪЯСНИТЕЛЬНАЯ И ПРОГНОСТИЧЕСКАЯ МОДЕЛИ В МЕДИЦИНЕ. ПРИНЦИПЫ ПОСТРОЕНИЯ И ВОЗМОЖНОСТИ ИСПОЛЬЗОВАНИЯ

**А. И. Кузнецов¹, Е. В. Щепкина^{2,3}, Т. В. Сушинская⁴, С. В. Епифанова⁵,
Д. М. Фаур⁶, А. Д. Каприн^{4,7,8}, Н. И. Стуклов⁴**

¹ ФГБУ ВО «Московский авиационный институт (национальный исследовательский университет)», Москва

² Российская академия народного хозяйства и государственной службы при Президенте РФ, Москва

³ ГБУЗ «Научно-практический клинический центр диагностики и телемедицинских технологий»
Департамента здравоохранения Москвы

⁴ МНИОИ им. П. А. Герцена, филиал ФГБУ «НМИЦ радиологии» Минздрава России, Москва

⁵ ФГБУ «Центральная клиническая больница с поликлиникой» Управления делами
Президента Российской Федерации, Москва

⁶ Российский экономический университет им. Г. В. Плеханова, Москва

⁷ Медицинский институт ФГАОУ ВО «Российский университет дружбы народов»

⁸ ФГБУ «НМИЦ радиологии» Минздрава России, г. Обнинск

Цель исследования. Провести систематический анализ данных, имеющихся в современной литературе, о возможности использования искусственного интеллекта (ИИ) для построения математических моделей сложных систем, в том числе человеческого организма.

Материал и методы. В обзор включены данные зарубежных и отечественных статей, найденных в Pubmed по данной теме, опубликованных за последние 10 лет.

Результаты. Алгоритмы машинного обучения помогают определять ключевые переменные и взаимосвязи внутри системы, которые людям трудно или невозможно обнаружить. В статье рассматриваются различные типы математических моделей: объяснительные и прогностические, объясняется важность и назначение выбора и стандартизации составляющих модель переменных и знака перед коэффициентами в моделях.

Заключение. Описательные и прогностические модели — это два распространенных типа моделей машинного обучения. Основное различие между ними заключается в цели их использования. Понимание этих различий важно для врачей-исследователей и аналитиков при выборе наиболее подходящего типа модели для своих исследований или для внедрения в процессы принятия решений.

Ключевые слова: искусственный интеллект, машинное обучение, диагностика, объяснительная и прогностическая модель, медицинские исследования, многофакторная логистическая регрессия, МЛР

ARTIFICIAL INTELLIGENCE — EXPLANATORY AND PROGNOSTIC MODELS IN MEDICINE. PRINCIPLES OF CONSTRUCTION AND POSSIBILITIES OF THE USE

**A. I. Kuznetsov¹, E. V. Shchepkina^{2,3}, T. V. Sushinskaya⁴, S. V. Epifanova⁵,
D. M. Faur⁶, A. D. Kaprin^{4,7,8}, N. I. Stuklov⁴**

¹ Federal State Budgetary Institution of Higher Education "Moscow Aviation Institute
(National Research University)", Moscow

² Russian Presidential Academy of National Economy and Public Administration, Moscow

³ State Budgetary Healthcare Institution "Research and Practical Clinical Center of Diagnostics and
Telemedicine Technologies" of Moscow Department of Healthcare, Moscow

⁴ P. A. Gertsen Moscow Scientific Research Oncological Institute, a Branch of Federal State Budgetary Institution "National Medical Research Center of Radiology" of the Ministry of Healthcare of the Russian Federation, Moscow

⁵ Federal State Budgetary Institution "Central Clinical Hospital with Polyclinics" of the Administrative
Directorate of the President of the Russian Federation

⁶ G. V. Plekhanov Russian University of Economics, Moscow

⁷ Medical Institute of Federal State Autonomous Educational Institution of Higher Education
"Russian University of Peoples' Friendship"

⁸ Federal State Budgetary Institution "National Medical Research Center of Radiology", Obninsk

Objective of the study is to carry out a systematic analysis of the data available in current literature on the possibilities of the use of artificial intelligence (AI) for the construction of mathematical models of complex systems, including human body.

Materials and Methods. The review comprises the data of foreign and Russian scholarly articles found in PubMed on the subject, published over the past 10 years.

Results. Machine learning algorithms help to identify key variables and relationships within a system that are difficult or impossible for humans to detect. This paper presents various types of mathematical models: explanatory and prognostic, explains the importance and purpose of the choice and standardization of variables that make up the model, as well as the signs of the coefficients in the models.

Conclusion. Descriptive and prognostic models are the two common types of models of machine learning. The key difference between them is an objective of their use. Understanding these differences is essential for clinician researchers and analysts when choosing the most appropriate type of model for their research or for the integration into decision-making processes.

Keywords: artificial intelligence, machine learning, diagnostics, explanatory and prognostic model, medical research, multivariate logistic regression, MLR

Введение

Искусственный интеллект (ИИ) произвел революцию во многих аспектах современной жизни, реализовав возможность построения математических моделей (ММ). ММ используются в самых разных областях как способ описания и прогнозирования сложных систем, в том числе и такой сложнейшей, как человеческий организм. Процесс построения ММ включает определение ключевых переменных и взаимосвязей внутри любой системы, которые людям трудно или невозможно обнаружить.

Один из способов, с помощью которого ИИ может помочь в создании ММ, — использование алгоритмов машинного обучения. Алгоритмы машинного обучения позволяют модели обучаться на большом наборе входных данных.

Типы моделей по использованию

Существуют различные типы ММ. Различаются они в зависимости от типа переменной, для которой эта модель используется. Переменная, используемая в ММ, может быть количественная или качественная.

Количественная переменная может быть непрерывной или дискретной. Примером непрерывной переменной может служить любое целое или дробное число, например показатель гемоглобина в анализе крови после проведенного медикаментозного лечения или размер опухоли после завершения лучевого лечения. Примером дискретной переменной может служить исход, который выражается с помощью

целых чисел, например возраст (числом полных лет). Полученные при этом ММ называют моделями регрессии.

Качественная переменная может быть порядковой или номинальной. Примером порядковой переменной может служить исход, который можно упорядочить с помощью целых чисел, например стадия рака или тяжесть состояния больного (легкое, среднее или тяжелое с помощью кодировки 1, 2 и 3). Примером номинальной переменной может служить диагноз. Например, рак молочной железы можно закодировать цифрой 1, рак шейки матки — 2, рак яичника — 3. Частным случаем номинальной переменной является бинарная переменная. Она используется для описания бинарного события, например есть ли у человека злокачественное образование или нет, имеются метастазы или нет. Полученную модель называют моделью классификации [1].

Построенная модель будет решать задачу классификации новых случаев, опираясь на их исходные данные. Примером такой задачи может быть диагностика болезни — заболел пациент (положительный результат) или нет (отрицательный результат).

В этой статье мы рассмотрим бинарный тип переменной, для моделирования которой используется классификация.

Типы моделей по ее открытости

Все модели, которые строит ИИ, можно условно разделить на открытые и закрытые. Еще их называют «белый» и «черный» ящики [2].

Модели «белого ящика» легко интерпретируемые, они открыты и понятны пользователям. Модели «черного ящика» не могут быть объяснены даже их создателями.

Мы рассмотрим алгоритм ИИ, который позволяет построить интерпретируемую модель классификации: многофакторную логистическую регрессию (МЛР, MLR — Multifactorial Logistic Regression).

Многофакторная логистическая регрессия

Основная идея логистической регрессии заключается в том, что пространство исходных значений может быть разделено линейной границей (то есть прямой) на две соответствующие классам области. Линейная граница в случае двух измерений — это просто прямая линия без изгибов. В случае трех — плоскость, и т.д. Эта граница задается в зависимости от имеющихся исходных данных и обучающего алгоритма. Чтобы все «работало», точки исходных данных должны разделяться линейной границей на две вышеупомянутые области. Если

точки исходных данных удовлетворяют этому требованию, то их можно назвать линейно разделяемыми [3].

Уравнение МЛР выглядит следующим образом [4]:

$$P(Y) = 1/(1+e^{-(b_0 + b_1*x_1 + \dots + b_n*x_n)}), \quad (1)$$

где Y — значение зависимой переменной; $P(Y)$ — вероятность принадлежности к одной из двух категорий зависимой переменной; e — основание натурального логарифма ($e \approx 2,72$);

x_1, \dots, x_n — значения первой ... n -й независимых переменных;

b_0 — константа;

b_1, \dots, b_n — регрессионные коэффициенты для соответствующих переменных [4].

Иными словами, суть алгоритма МЛР состоит в том, что он подбирает значения коэффициентов b_0, b_1, \dots, b_n для уравнения (1), чтобы предсказать значение Y максимально качественно. Значения b_0, b_1, \dots, b_n могут быть

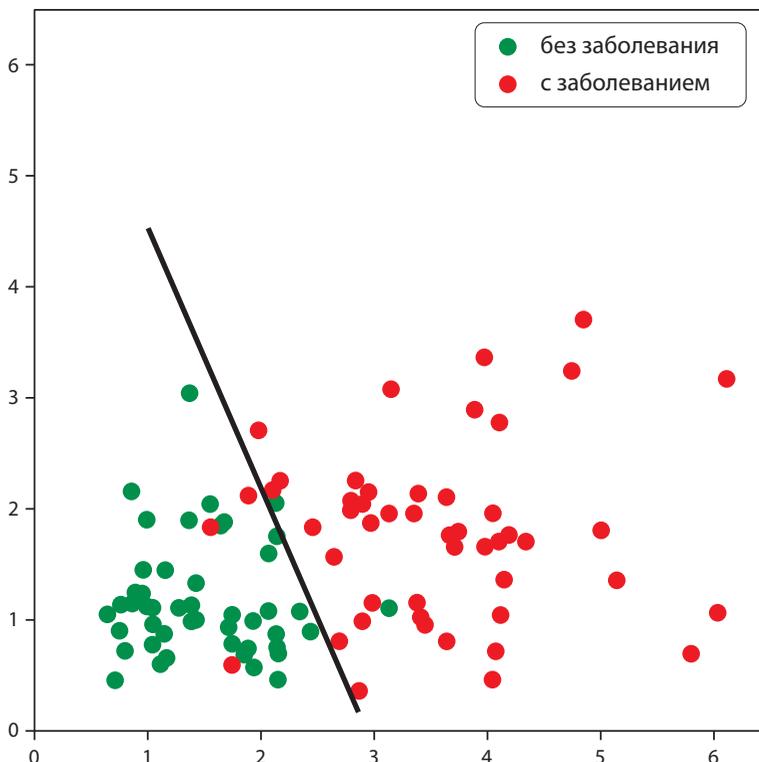


Рис. 1. Модель (черная прямая линия), разделяющая на две группы пациентов в двухмерном пространстве признаков, построенная методом МЛР

Матрица путаницы (Confusion matrix)

		Истинное значение исхода (например, наличие заболевания) *	
		Есть (1)	Нет (0)
Предсказанное значение исхода**	Есть (1)	Истинно положительный (TP)	Ложно положительный (FP)
	Нет (0)	Ложно отрицательный (FN)	Истинно отрицательный (TN)

* Истинное значение исхода определяется на основании «золотого стандарта», принятого в медицине при определении данного заболевания.

** Предсказанное значение исхода определяется на основании результата работы ММ.

как положительными, так и отрицательными. Количество переменных и сам набор переменных x_1, \dots, x_n должен быть predetermined до начала запуска алгоритма МЛР. Более подробно о процессе выбора количества переменных и самого набора переменных написано в разделе «Выбор переменных».

Метрики оценки качества ММ

Суть алгоритма МЛР состоит в том, что он подбирает значения коэффициентов b_0, b_1, \dots, b_n для уравнения (1), чтобы предсказать значение Y максимально качественно. Но каким образом определяется это понятие «максимально качественно»? Для оценки качества работы модели классификации, в том числе и МЛР, используются различные метрики. Рассмотрим наиболее популярные из них.

Матрица путаницы (Confusion matrix) — это таблица, которая отображает истинные и предсказанные значения ММ. В дальнейшем эту матрицу используют для расчета других метрик качества модели, такие как точность, чувствительность, специфичность, ROC-AUC и др.

Чувствительность (истинно положительная пропорция) — это доля действительно болеющих, которые по результатам работы ММ выявляются именно как больные. Эта мера важна, так как показывает вероятность того, что любой случай данной болезни будет выявлен с помощью ММ. Если ММ имеет высокую чувствительность, то она полезна врачу для исключения диагноза, если результат получился отрицательным.

$$\text{Чувствительность (Sensitivity)} = TP / (TP + FN)$$

Специфичность (истинно отрицательная пропорция) — это доля пациентов, действи-

тельно не имеющих заболевания, среди пациентов, у которых и ММ не выявила этого заболевания. Благодаря этой мере можно определить вероятность достоверного выявления ММ людей, которые истинно не имеют данного заболевания.

$$\text{Специфичность (Spasticity)} = TN / (TN + FP)$$

Точность — это доля истинных (положительных и отрицательных) результатов работы ММ к общему числу полученных результатов. Если ММ имеет высокую точность, то это означает, что ММ правильно ставит диагноз.

$$\text{Точность (Accuracy)} = (TP + TN) / (TP + TN + FP + FN)$$

Метрика «Точность» хорошо работает, когда ММ строится или обучается по сбалансированной базе, то есть когда количество больных и здоровых в ней примерно одинаковое. Но такая ситуация в медицине случается крайне редко, если только не специально к ней идти. Когда база для обучения является несбалансированной, следует использовать метрику ROC-AUC.

ROC-AUC

ROC-кривая (Receiver Operating Characteristic) — это графическое представление производительности модели путем построения графика «Чувствительность» в сравнении с «1-Специфичность».

В качестве количественной меры интерпретации ROC-кривой используется мера ROC-AUC, которая является площадью под кривой ROC. Чем выше показатель AUC, тем качественнее классификатор, при этом значение, близкое к 0,5, демонстрирует непригодность выбранной ММ и соответствует случайному

гаданию. ROC-AUC является мерой общей производительности ММ вне зависимости от пороговых (cut-off) значений и предоставляет собой единое значение для сравнения различных моделей между собой.

Каждая из описанных метрик оценки качества ММ дает ценную информацию о ее производительности и может помочь определить направления для ее улучшения.

Типы моделей по цели/назначению

Цель алгоритма МЛР — найти значения коэффициентов при независимых переменных, которые лучше всего вычисляют переменную исхода (результата). Алгоритм МЛР использует математическую формулу для определения коэффициентов для каждой независимой переменной. Эта формула получается путем минимизации суммы квадратов разностей между прогнозируемыми значениями и фактическими значениями зависимой переменной (той переменной, которую мы моделируем), что достигается с помощью процесса, называемого методом наименьших квадратов (МНК). Коэффициенты перед каждой независимой переменной могут дать представление о силе и направлении взаимосвязи между этой независимой переменной и переменной исхода (зависимой переменной).

Таким образом, алгоритм МЛР нацелен на решение двух целей: найти значение коэффициента и знак перед этим значением для каждой из независимых переменных, которые лучше всего позволяют *предсказывать* переменную исхода и *объяснять* взаимосвязь между независимыми переменными и переменной

исхода. Благодаря такой способности МЛР можно настроить таким образом, что алгоритм позволит построить две разные модели, одна будет лучше предсказывать, а вторая — лучше объяснять описываемое явление. Однако при этом у объяснительной модели точность может быть хуже, чем у предсказательной. А у предсказательной модели объяснительные способности будут хуже, чем у объяснительной.

Решение целей МЛР двумя разными моделями имеет смысл, когда планируются два разных применения этих моделей. Описательные модели предназначены для описания характеристик данных и закономерностей в них в исследовательских целях, когда цель состоит в том, чтобы понять данные. Описательные модели более понятны для врачей, склонных к анализируванию симптомов при формировании диагноза.

Прогностические модели нацелены на предсказание. Эти модели используются для прогнозирования будущих событий (возникнет рецидив через три года или нет) или результатов (есть метастазы или нет) [5]). Такие модели также могут использоваться врачами для постановки диагноза.

Еще одно различие между описательной и прогностической моделями заключается в алгоритмах, используемых для их построения (табл. 2).

Стандартизация переменных

Первым этапом создания ММ является стандартизация данных. Прежде чем применять процедуры стандартизации, важно понимать природу входных переменных и требования ММ.

Таблица 2

Сравнение алгоритмов построения описательной и прогностической моделей

	Описательная/ объяснительная модель	Прогностическая модель
Стандартизация переменных	Важна, но не всегда	
Выбор переменных	Статистическая значимость	Специальные методы выбора важных переменных
Корреляция	Входные переменные не коррелируют между собой	Неважно, коррелируют между собой входные переменные или нет
Знак при коэффициенте перед переменной (+или-)	Отражает направление влияния	Необязательно отражает направление влияния
Удаление переменных с малыми коэффициентами	Возможно при проведении специальных процедур	

Процедуры стандартизации следует использовать, когда входные переменные имеют разные масштабы. Например, в модели, которая моделирует, например, наличие рака шейки матки (РШМ) на основе возраста и показателей периферической крови пациенток, возраст может варьироваться от 18 до 99 лет, тогда как некоторые показатели крови, например эритроциты, могут иметь значения с двенадцатью нулями (10^{12}). В этом случае следует использовать процедуры стандартизации для преобразования переменных в общую шкалу. Стандартизация масштабирует данные так, чтобы среднее значение равнялось 0, а стандартное отклонение — 1. Без стандартизации модели могут придавать больший вес переменным с более крупными масштабами, что приводит к необъективным и неточным прогнозам. Стандартизация также помогает увеличить скорость сходимости алгоритмов оптимизации, используемых для обучения моделей.

Однако важно использовать процедуры стандартизации только тогда, когда входные переменные имеют разные масштабы. Если масштабы сопоставимы, то стандартизацию можно не использовать. Также процедуры стандартизации не следует использовать, когда входные переменные являются категориальными¹ или когда алгоритмы построения моделей не требовательны к стандартизации, например в ММ, основанных на «деревьях решений». Категориальные переменные представляют собой величины, не имеющие числового значения, такие как пол, диагноз или степень/стадия заболевания. Процедуры стандартизации не имеют смысла для категориальных переменных, поскольку их значения не имеют величины.

Процедура стандартизации особенно важна при построении объяснительной модели. Именно в этом случае полученные при входных переменных коэффициенты будут пока-

зывать, насколько каждая входная переменная важна при построении модели.

Например, если полученное уравнение выглядит так:

$$P(Y) = 1/(1 + e^{-(3 + 2,5*x_1 + 0,3*x_2)}),$$

то это значит, что переменная x_1 более значимо влияет на исход, так как при ней стоит больший коэффициент (2,5), чем при x_2 . Влияние переменной x_2 на исход менее значимо, так как коэффициент при ней меньше, чем при переменной x_1 : $0,3 < 2,5$.

Выбор набора переменных

После этапа стандартизации данных в прогностическом моделировании следует провести выбор необходимых для построения модели входных переменных — подмножества переменных, которые будут использоваться для построения модели. Цель состоит в том, чтобы выбрать набор переменных, оказывающих существенное влияние на переменную исхода, и избежать переменных, оказывающих незначительное влияние или не влияющих вовсе.

Такой выбор позволяет уменьшить сложность модели за счет сокращения количества переменных и улучшить ее обобщаемость, а значит, и точность исхода.

Модель со слишком большим количеством входных переменных может быть подвержена переобучению. Переобучение заключается в том, что построенная модель будет очень точно работать на обучающих данных и плохо — на тестовых данных. С другой стороны, модель с малым количеством входных переменных может не отразить все важные взаимосвязи между входными переменными и интересующим нас исходом.

Процесс выбора нужных для описательных и прогностических моделей переменных происходит по-разному.

Для описательных моделей наиболее распространенным статистическим методом является однофакторный регрессионный анализ. Анализируется каждая входная переменная по отдельности. Если входная переменная статистически значимо влияет на исход, то она

¹ Качественная, дискретная или категориальная переменная — переменная, которая может принимать одно из ограниченного и обычно фиксированного числа возможных значений, назначая каждую единицу наблюдения определенной группе или номинальной категории на основе некоторого качественного свойства.

остаются в наборе выбранных переменных, если нет, то из него удаляется.

Далее проводится отбор необходимых входных переменных с помощью многофакторной логистической регрессии методом пошаговой обратной или прямой селекции.

Для прогностических моделей наиболее распространенным методом выбора входных переменных является метод RFE (Recursive Feature Elimination — рекурсивный отбор признаков). Далее на полученном наборе входных переменных с помощью МЛР строится модель.

Одной из проблем выбора признаков для ММ является работа с многомерными данными («проклятие размерности»), которые относятся к наборам данных с большим количеством переменных при малом количестве наблюдений. В этих случаях традиционные статистические методы могут оказаться неэффективными.

Корреляция

Еще одна проблема, которая возникает при выборе переменных, заключается в том, следует ли использовать все коррелированные между собой входные переменные при построении ММ или часть из них лучше удалить.

Когда две или более входные переменные сильно коррелированы между собой, то это может привести к тому, что они начинают компенсировать друг друга, затрудняя выявление независимого влияния каждой: становится трудно определить степень влияния любой из них на исход. Особенно это важно при построении описательных моделей, так как в этом случае необходимо объяснить, от каких входных переменных больше всего зависит исход.

Исключение сильно коррелированных переменных также полезно для уменьшения размерности модели. Вместо того чтобы включать в модель обе переменные, мы можем выбрать одну, которая больше воздействует на исход, и отбросить другую.

Прогностическая модель позволяет использовать коррелированные (взаимозависимые) входные переменные. Следует заметить, что использование коррелированных переменных

даже в описательной модели не всегда плохо. В некоторых случаях две переменные могут быть сильно коррелированы, но каждая сама по себе предоставляет уникальную информацию, важную для получения результата. Например, если мы строим модель для определения риска сердечно-сосудистых заболеваний, то мы можем использовать как артериальное давление, так и уровень холестерина в качестве предикторов, даже если они сильно коррелируют между собой.

Таким образом, использование сильно коррелированных входных переменных при построении объяснительной или прогностической модели может быть как выгодным, так и невыгодным. Поэтому следует тщательно взвешивать все «за» и «против» и принимать обоснованное решение о включении коррелированных переменных в модели.

Знак перед переменной: плюс или минус

После выбора необходимых входных переменных следующим шагом является определение знака (плюс или минус) каждой входной переменной в модели. Для этого существует несколько способов.

Первый включает в себя измерение корреляции между входной переменной и переменной исхода. Например, если у нас есть две переменные, X и Y , и они положительно коррелированы, то увеличение X приведет к увеличению Y . С другой стороны, если переменные имеют отрицательную корреляцию, то увеличение X приведет к снижению Y . Если корреляция положительная, то ставится знак плюс, а если корреляция отрицательная, знак минус. Этот метод используется, когда связь между переменной и результатом является линейной.

Другой метод основан на экспертных знаниях. В этом методе эксперты в предметной области (например, профильные врачи) дают свое представление о взаимосвязи между входной переменной и переменной исхода. Этот метод используют, когда взаимосвязь между переменными не является линейной или если между входной переменной и переменной

исхода отсутствует статистически значимая корреляция.

Третий метод основан на методе проб и ошибок. В этом методе переменной присваиваются разные коэффициенты, а модель строится и оценивается для определения наилучшего набора значений коэффициентов. Этот метод трудоемок и требует значительных усилий, но может быть полезен при отсутствии четкой связи между переменными.

В объяснительной модели знак перед переменной отражает направление влияния входной переменной на исход. Например, если мы строим модель для объяснения наличия рака у человека, то знак плюс перед переменной будет обозначать, что с увеличением значения, например количества тромбоцитов, растет вероятность наличия рака у человека в момент исследования, а знак минус, например перед показателем гемоглобина, будет означать, что с увеличением этого показателя снижается вероятность наличия рака в момент исследования.

Знак перед входными переменными в прогностической модели не обязательно может отражать направление их влияния на исход, как при линейной зависимости в МЛР.

Удаление переменных с малыми коэффициентами

В моделировании обычной практикой является построение моделей с использованием нескольких входных переменных и анализ их влияния на переменную исхода. Однако не все переменные оказывают одинаковое влияние на переменную исхода, и некоторые могут иметь низкое значение полученного коэффициента, что указывает на более слабую связь с переменной исхода. В связи с этим возникают следующие вопросы: можно ли удалить из модели переменные с низкими коэффициентами, ухудшит или улучшит это работу модели?

Для этого важно понять роль коэффициентов в модели. В машинном обучении коэффициенты представляют силу и направление связи между входными переменными и выходной переменной. Чем выше значение коэффициента, тем сильнее связь между входной переменной и исходом.

С одной стороны, низкие коэффициенты могут указывать на реальную слабую связь, на имеющийся шум в данных или мультиколлинеарность (взаимозависимость) входных переменных в модели. В этом случае их можно и нужно из модели удалять.

С другой стороны, низкий коэффициент не обязательно означает, что входная переменная не влияет на переменную исхода. Кроме того, удаление переменных без разбора может привести к переобучению модели, что приводит к высокому риску ложноположительных и ложноотрицательных результатов.

Для этого важно использовать систематический и строгий подход к удалению переменных из модели. Одним из таких подходов является использование методов регуляризации, которые «наказывают» модель за использование слишком большого количества переменных или удаляют переменные с низкими коэффициентами, сохраняя при этом переменные, которые сохраняют точность модели.

Следовательно, удаление переменных с низкими коэффициентами из-за их кажущейся недостаточной важности не всегда целесообразно, так как низкие значения коэффициента не обязательно означают, что переменная незначима. Более того, удаление переменных без разбора может привести к переобучению. Следовательно, решение об удалении переменных должно быть основано на систематическом и строгом подходе, учитывающем вклад переменной в точность модели.

Заключение

Описательные и прогностические модели — это два распространенных типа моделей машинного обучения. Основное различие между ними заключается в цели их использования. Описательные модели предназначены для описания и выявления закономерностей в данных, в то время как прогностические модели предназначены для прогнозирования будущих результатов на основе имеющихся данных.

Описательные модели часто используются при исследовательском анализе данных, целью которого является понимание и объяснение.

Прогностические модели чаще используются в процессах принятия решений, целью которых является прогнозирование будущих событий или результатов.

Понимание различий между этими типами моделей важно для врачей-исследователей и аналитиков при выборе наиболее подходяще-

го типа модели для своих исследований или для внедрения в процессы принятия решений.

Однако может случиться и так, что описательная модель делает качественные предсказания [5]. В этом случае строить отдельную прогностическую модель не имеет смысла.

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. Мартынов А. О. Разработка программного обеспечения для проведения регрессионного анализа данных с предварительной оценкой типов шкал переменных и рекомендацией допустимых методов / А. О. Мартынов // Проблемы управления в социально-экономических и технических системах: Материалы XVII Международной научно-практической конференции, Саратов, 08–09 апреля 2021 года. — Саратов: ИЦ «Наука», 2021. — С. 150–154.
2. Иванова А. П. Правовые проблемы использования искусственного интеллекта в сфере здравоохранения / А. П. Иванова // Социальные и гуманитарные науки. Отечественная и зарубежная литература. Серия 4: Государство и право. — 2021. — № 1. — С. 151–159. — DOI 10.31249/rgpravo/2021.01.16.
3. <https://habr.com/ru/companies/io/articles/265007/>
4. Шарашова Е. Е., Холматова К. К., Горбатова М. А., Гржибовский А. М. Применение множественного линейного регрессионного анализа в здравоохранении с использованием пакета статистических программ SPSS // Наука и здравоохранение. — 2017. — № 3. — С. 5–31
5. Патент № 2750769 С2 Российская Федерация, МПК G01N 33/49. Способ диагностики метастазов в лимфатические узлы малого таза у больных резектабельным раком шейки матки: № 2020142386: заявл. 22.12.2020; опубл. 02.07.2021 / А. Д. Каприн, Н. И. Стулков, Т. В. Сушинская [и др.]; заявитель Федеральное государственное бюджетное учреждение «Национальный медицинский исследовательский центр радиологии» Министерства здравоохранения Российской Федерации. — EDN OZBVKR.

СВЕДЕНИЯ ОБ АВТОРАХ

Кузнецов Антон Игоревич, программист, студент кафедры «Прикладные программные средства и математические методы института № 3 «Системы управления, информатика и электроэнергетика» Московского авиационного института (Национальный исследовательский университет), 125080, Москва, Волоколамское шоссе, д. 4, e-mail: drednout5786@yandex.ru; ORCID ID 0000–0003–2182–5792, SPIN: 8824–9080.

Kuznetsov Anton I., programmer, student of the Department of Applied Software and Mathematical Methods of the Faculty of Control Systems, Informatics & Electricity of Moscow Aviation Institute (National Research University), Russia, 125080, Moscow, Vernadsky Avenue, 4, e-mail: drednout5786@yandex.ru; ORCID ID 0000–0003–2182–5792, eLibrary SPIN: 8824–9080.

Щепкина Елена Викторовна, кандидат социологических наук, заместитель начальника отдела сводного контингента и статистики Учебно-методического управления в Российской академии народного хозяйства и государственной службы при Президенте Российской Федерации (РАНХиГС), исследователь данных в ГБУЗ «Научно-практический клинический центр диагностики и телемедицинских технологий» Департамента здравоохранения Москвы, 119571, Москва, проспект Вернадского, д. 82, стр. 1; 127051, Москва, ул. Петровка, д. 24, стр. 1, e-mail: elenaschepkina@gmail.com; ORCID ID 0000–0002–2079–1482, SPIN: 2347–9436, AuthorID: 959277, Scopus Author ID: 57211515165

Schepkina Elena V., PhD, Deputy Head of the Department of Statistics and the Consolidated Contingent of the Educational and Methodological Department at the Presidential Academy — RANEPA, Data scientist of the State Healthcare Institution Scientific and Practical Clinical Center for Diagnostics and Telemedicine Technologies of the Moscow Department of Healthcare, 119571, Moscow, Vernadsky Avenue, 82, building 1; 127051, Moscow, st. Petrovka, 24, building 1, 4, e-mail: elenaschepkina@gmail.com; ORCID ID 0000–0002–2079–1482, SPIN: 2347–9436, AuthorID: 959277, Scopus Author ID: 57211515165

Сушинская Татьяна Валентиновна, кандидат медицинских наук, старший научный сотрудник отдела опухолей репродуктивных и мочевыводящих органов МНИОИ им. П. А. Герцена, филиала ФГБУ «НМИЦ радиологии» Минздрава России, 125284, Москва, 2-й Боткинский проезд, д. 3; ORCID ID 0000–0001–8812–9105. SPIN-код: 7283–0014, AuthorID: 446611

Sushinskaya Tatyana V., C. Sc. (Med.), senior researcher, P. Hertsen Moscow Oncology Research Institute — Branch of the National Medical Research Radiological Centre, 3, 2nd Botkinskiy lane, Moscow, 125284, Russian Federation; ORCID ID 0000-0001-8812-9105. SPIN-код: 7283-0014, AuthorID: 446611

Епифанова Светлана Викторовна, кандидат медицинских наук, врач-рентгенолог отделения рентгеновской диагностики и томографии ФГБУ Центральная клиническая больница с поликлиникой Управления делами Президента Российской Федерации, врач-рентгенолог в ГБУЗ «Научно-практический клинический центр диагностики и телемедицинских технологий» Департамента здравоохранения Москвы, 121359, Москва, ул. Маршала Тимошенко, д. 15, 127051, Москва, ул. Петровка, д. 24, стр. 1, e-mail: svepifanova@yandex.ru; ORCID ID 0000-0002-7591-5120, SPIN-код 9067-5033

Epifanova Svetlana V., PhD, Radiologist of Radiology and Tomography Department Federal State Institution Central Clinical Hospital with Out-Patient Clinic of the Presidential Administration of the Russian Federation, Radiologist of the Department of Expertise and Quality of the State Healthcare Institution Scientific and Practical Clinical Center for Diagnostics and Telemedicine Technologies of the Moscow Department of Healthcare, 121359, Moscow, st. Marshal Timoshenko, 15, 127051, Moscow, st. Petrovka, 24, building 1, e-mail: svepifanova@yandex.ru; ORCID ID 0000-0002-7591-5120, SPIN-код 9067-5033

Фаур Дарий Мохаматович, студент факультета Высшей школы экономики и бизнеса РЭУ им. Г. В. Плеханова, 117997, Москва, Стремянный пер., д. 36, e-mail: dafa5801@gmail.com; ORCID ID 0009-0006-4756-4681.

Faur Dariy M., student of the faculty of the “Higher School of Economics and Business” of the Plekhanov Russian University of Economics, 117997, Moscow, Stremyanny lane 36, e-mail: dafa5801@gmail.com; ORCID ID 0009-0006-4756-4681

Каприн Андрей Дмитриевич, академик РАН, доктор медицинских наук, профессор, заслуженный врач РФ, член-корреспондент РАО, генеральный директор ФГБУ «НМИЦ радиологии» Минздрава России, г. Обнинск, Российская Федерация; директор МНИОИ им. П. А. Герцена — филиал ФГБУ «НМИЦ радиологии» Минздрава России, Москва; заведующий кафедрой урологии и оперативной нефрологии с курсом онкоурологии медицинского факультета, ФГАОУ ВО «Российский университет дружбы народов», Москва, e-mail: mnioi@mail.ru; ORCID ID 0000-0001-8784-8415, SPIN: 1759-8101, AuthorID: 96775, ResearcherID: K-1445-2014, Scopus Author ID: 6602709853

Kaprin Andrey D., academician of Russian Academy of Sciences, Dr. Sci. (Med.), professor, honored doctor of the Russian Federation, corr. member of the RAE, general director National Medical Research Radiological Centre, Obninsk, Russian Federation; director at the P. A. Hertsen Moscow Oncology Research Institute — Branch of the National Medical Research Radiological Centre, Moscow, Russian Federation; head of the department of urology and operative Nephrology with the course of oncurology of the Medical Institute, Peoples' Friendship University of Russia, Moscow, Russian Federation, e-mail: mnioi@mail.ru; ORCID ID 0000-0001-8784-8415, SPIN: 1759-8101, AuthorID: 96775, ResearcherID: K-1445-2014, Scopus Author ID: 6602709853

Стуклов Николай Игоревич, доктор медицинских наук, руководитель курса гематологии, профессор кафедры госпитальной терапии с курсами эндокринологии, гематологии и клинической лабораторной диагностики Медицинского института РУДН, 117198, Москва, ул. Миклухо-Маклая, д. 8; главный научный сотрудник отделения высокодозной химиотерапии с блоком трансплантации костного мозга МНИОИ им. П. А. Герцена — филиала ФГБУ «НМИЦ радиологии» Минздрава России, 125284, Москва, 2-й Боткинский проезд, д. 3, e-mail: stuklovn@gmail.com; ORCID ID 0000-0002-4546-1578

Stuklov Nikolay I., Dr. Sc. (Med.), Head of the Course of Hematology professor of the Department of Hospital Therapy with the Courses of Endocrinology, Hematology, & Clinical Laboratory Diagnostics, Medical Institute of the Russian University of Peoples' Friendship; 8, Miklukho-Maklaya str., Moscow, 117198, Russian Federation; principal researcher, P. Hertsen Moscow Oncology Research Institute — Branch of the National Medical Research Radiological Centre; 3, 2nd Botkinskiy pass., Moscow, 125284, Russian Federation, e-mail: stuklovn@gmail.com; ORCID ID 0000-0002-4546-1578