

2. Stroev, S.P., Russkikh, T.N., Tinyakova, V.I. (2019). *Modeli risk-menedzhmenta poter' ot del'nogo podrazdeleniya promyshlennogo predpriyatiya* [Risk Management Models of Losses of Separate Divisions at an Industrial Enterprise]. *Sovremennaya ekonomika: problemy i resheniya* [Modern Economics: Problems and Solutions], 10, 32-46. (In Russ., abstract in Eng)
3. Stroev, S.P., Sekerin, A.B., Selyutin, V.D. (2008). *Upravleniye riskom ekonomicheskoy nesostoyatel'nosti promyshlennogo predpriyatiya s razvetvlennoy proizvodstvenno-tekhnologicheskoy strukturoy* [Risk Management of Economic Insolvency of an Industrial Enterprise with an Extensive Industrial and Technological Structure]. *Upravlenie riskom* [Risk Management], 34, 72-84. (In Russ., abstract in Eng.)

DOI: 10.24888/2500-1957-2021-2-98-108

УДК
004.89,
32.972

**ПОДХОД К МОДЕЛИРОВАНИЮ И АНАЛИЗУ ДАННЫХ
НА ОСНОВЕ РАЗВИТИЯ АЛГОРИТМОВ МАШИННОГО
ОБУЧЕНИЯ**

Черномордов Сергей Викторович
аспирант
Chernomor96@list.ru
г. Елец

Опенкин Даниил Юрьевич
аспирант
openkin.study@mail.ru
г. Елец

Елецкий государственный университет
им. И.А. Бунина

Аннотация. Актуальной задачей является развитие подходов к моделированию и анализу данных на основе интеллектуальных алгоритмов. В данной работе рассматриваются вопросы построения и анализа математических моделей динамических систем с интеллектуальными компонентами. Рассмотрены вопросы применения метода главных компонент для решения задач машинного обучения, в частности, для решения задачи регрессии. Проанализированы примеры интеллектуального анализа данных с использованием набора данных «Ирисы Фишера».

Ключевые слова: интеллектуальный анализ данных, набор данных «Ирисы Фишера», Python, метод главных компонент, машинное обучение.

Введение

В процессе количественных и структурных изменений информации в современном мире наибольшую актуальность приобретают задачи поиска релевантных методов получения, сбора, аккумулирования, обработки, передачи и распространения информации. В этой связи развитие сферы IT происходит гораздо быстрее, чем большинства более фундаментальных областей человеческого знания. Благодаря развитию цифровых технологий накопленные человечеством знания можно представить в виде данных. Таким образом, на первый план выходит Data Science – наука о данных, которая сочетает в себе такие области знания, как информатика, математика и системный анализ. Содержательной основой Data Science является обработка больших данных (Big Data), интеллектуальный анализ данных (Data Mining), статистические методы, методы искусственного интеллекта, включая машинное

обучение (Machine Learning). На сегодняшний день Data Science востребована в различных прикладных сферах человеческой деятельности: от космологии до здравоохранения, от маркетинга и менеджмента до прогнозирования природных катаклизмов.

При построении систем машинного обучения специалисты работают с информационными технологиями, математическим анализом и статистикой. В текущих условиях это одна из самых широко распространенных и актуальных областей. При помощи искусственного интеллекта (ИИ) создается всё больше потребительских продуктов, что укрепляет позиции ИИ на современном рынке. В перспективе результаты деятельности ИИ станут частью повседневной рутины многих областей человеческой профессиональной деятельности. Однако разработка систем машинного обучения на данном этапе не может обойтись без существенных затрат средств и времени высококвалифицированных специалистов как в сфере искусственного интеллекта, так и в той предметной области, где подобная технология применяется.

Наиболее перспективной и актуальной в настоящее время является технология автоматизированного машинного обучения – комплекс инструментальных и методических средств, позволяющий значительно сократить долю человеческого участия в создании систем искусственного интеллекта, в том числе средствами автоматической валидации результатов моделирования.

В качестве математической и инструментальной основы машинного обучения сегодня центральное место занимают искусственные нейронные сети. Они стали своеобразным универсальным языком представления обучаемых моделей. Важнейшими проблемами нейросетевого моделирования являются проблемы разработки эффективных методов машинного обучения. Некоторые вопросы построения алгоритмов машинного обучения рассмотрены в [5, 7, 11].

Целью интеллектуального анализа данных является обнаружение неявных закономерностей в наборах данных. Разработка интеллектуального анализа данных (data mining) позволила выявлять значимые корреляции, образцы и тенденции в больших объемах слабо формализованных данных, а применение метода нейронных сетей (НС) сделало возможным поиск значения неизвестных переменных или характеристик по известным данным наблюдений или измерений [6]. Технологии Data Mining спроектированы для осуществления процесса обнаружения или извлечения необходимых знаний из массива данных, которые могут храниться в разных источниках: файловых системах, базах данных, хранилищах и др. Методы интеллектуального анализа данных эффективно применяются при разработке бизнес стратегий, в научных и медицинских исследованиях, а также при регулировании управленческой деятельности.

В основе обучения нейронных сетей лежит процесс накопления опыта, экстраполяции знаний для новых случаев, извлечения определенных свойств из обрабатываемой информации и отделения излишних данных. В процессе нейросетевого моделирования важно сформировать обучающую выборку для нейронной сети.

Несмотря на тот факт, что за последние десять лет показатели уровня развития машинного обучения достигли значительных высот, их пределы, как и вся область искусственного интеллекта, не могут быть до конца определены. Предметом прогнозирования ИИ могут являться большинство известных параметров измерений, от времени до температуры. Кроме того, актуальным остается направление создания правдоподобных изображений. Однако для решения каждой конкретной задачи используется специализированный метод машинного обучения, применяющийся в вычислительных технологиях ИИ.

В настоящей работе рассмотрены вопросы применения метода главных компонент для решения задач машинного обучения, в частности, для решения задачи регрессии. Изучен пример интеллектуального анализа данных с использованием набора данных «Ирисы Фишера». Для указанного набора данных предложена структура нейронной сети. Рассмотрены

перспективы использования дискриминационного анализа данных для моделирования технических систем с переключениями.

Топологии искусственных нейронных сетей

Выбор подходящей нейросети для решения научно-исследовательских задач является одним из важнейших аспектов моделирования, в процессе которого могут использоваться различные типы и модификации НС.

Нейронная сеть является комплексом элементов, схожих с нейронами человеческого мозга. Элементы сопрягаются конкретным способом не только между собой, но и с окружающей средой посредством соединений, определяющихся весовыми коэффициентами. Исходя из того, какие функции выполняют нейроны, их можно классифицировать как входные нейроны, выходные нейроны, промежуточные нейроны.

С помощью переработки полученной информации во время процесса функционирования НС происходит преобразование входного сигнала в выходной. От характеристик всей архитектуры НС и ее отдельных элементов зависит, какой тип преобразования данных будет выполняться сетью.

Важно отметить, что НС реализуются на основе математических операций и набора параметров, необходимых для определения выходных данных. Один из вариантов классификации нейронных сетей предложен на рис. 1.

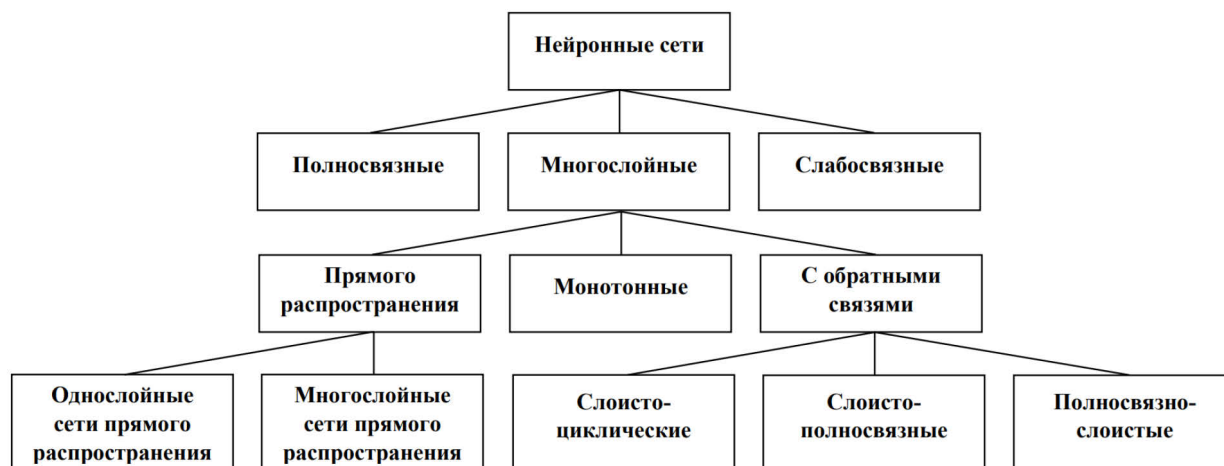


Рис. 1. Классификация НС по топологии

Полносвязные нейронные сети представляют собой тип НС, в архитектуре которой все узлы или нейроны на одном уровне подключены к нейронам на следующем уровне. Полносвязные сети очень широко применимы и, как правило, имеют более низкую производительность, чем специализированные сети, настроенные на структуру проблемного пространства [3].

Многослойные сети обладают еще более сложной конфигурацией, которая может иметь три или более уровней. Этот тип НС является связанным, при этом узлы, присутствующие в данном слое, подключаются к узлам, которые присутствуют в слое следующего уровня. Внешние сигналы в данной ситуации передаются на входы нейронов нулевого слоя. Выходами сети являются выходные сигналы последнего слоя.

Многослойные НС подразделяются на следующие типы.

1. Сети прямого распространения – это простейшая форма нейронных сетей, у которой отсутствуют обратные связи. Входные данные двигаются лишь в одну сторону, проходя через нейронные узлы и выходя через узлы вывода. Сети бывают однослойными или многослойными с прямым распространением (ПР).

Простейшая сеть ПР имеет два слоя:

- слой входных нейронов, который не учитывается, так как в нем не выполняются вычисления;

- слой выходных нейронов, который формируется при применении просуммированных весовых коэффициентов к входным узлам.

Отличительным признаком многослойной сети можно назвать присутствие одного или нескольких скрытых слоев, которые являются внутренними для сети и не соотносятся с внешним слоем. Скрытые слои трансформируют информацию и делают модель нелинейной.

Сети прямого распространения применяются для распознавания биометрических данных в таких сферах, как безопасность, здравоохранение и маркетинг.

2. Монотонные сети представляют собой частный случай слоистых сетей с добавочными условиями на связи и нейроны. Каждый из слоев, кроме последнего (выходного), содержит два блока: возбуждающий и тормозящий. Для нейронов таких сетей характерна монотонная зависимость выходного сигнала нейрона от конфигурации входящих сигналов.

3. Рекуррентные нейронные сети представляют собой сети, для которых характерно сохранение выходных данных какого-либо слоя и их передача обратно на вход. Первый уровень формируется так же, как и в сети прямого распространения, т.е. с помощью произведения суммы весов и характеристик. Однако на дальнейших уровнях начинается рекуррентный процесс нейронной сети. Иначе говоря, каждый узел выполняет функцию ячейки памяти при вычислении и выполнении операций.

Далее в работе будет выполнена оценка возможности применения указанных типов НС к анализу некоторых специальным образом организованных наборов данных. Прежде чем перейти к анализу данных, опишем особенности математических библиотек, применяемых для программной реализации нейросетевых алгоритмов обработки данных.

Главные математические библиотеки Python

Дополнительные расширения (библиотеки), созданные для языка Python, превращают его в благоприятную среду для математических исследований, связанных с построением нейросетевых алгоритмов. Степень сложности процесса построения математического программного обеспечения зависит от того, какие языки программирования были изначально использованы при написании данных библиотек.

Библиотека NumPy обладает реализует работу с разнообразными математическими структурами данных, в частности многомерными массивами и матрицами. Библиотека гарантирует эффективные тензорные вычисления с матрицами и массивами. NumPy написана на языках Python и C.

Библиотека SciPy основана на структурах данных NumPy и его базовых функциях управления. SciPy расширяет возможности NumPy дополнительными полезными функциями поиска минимумов и максимумов функций; вычисления интегралов функций; поддержки специальных функций; обработки сигналов и изображений; работы с генетическими алгоритмами; решения обыкновенных дифференциальных уравнений и др. Библиотека написана на языках Python, C, Fortran, C++ и Cython.

Библиотека SymPy является быстро развивающейся библиотекой Python с открытым исходным кодом для выполнения символьных вычислений. Данная библиотека призвана стать альтернативой таким системам, как Mathematica или Maple, сохраняя при этом максимально простой и легко расширяемый код. На сегодняшний день библиотека SymPy занимает лидирующие позиции среди систем компьютерной алгебры и включает в себя различные функции, от базовой символьной арифметики до исчисления, алгебры, дискретной математики и квантовой физики. SymPy полностью написан на языке Python и не требует никаких внешних библиотек.

Библиотека Matplotlib – это наиболее часто используемая библиотека для создания статических, анимированных и интерактивных визуализаций в Python. Одной из наиболее важных функций Matplotlib является его способность эффективно работать со многими операционными системами и графическими процессорами. Библиотека Matplotlib поддерживает десятки бэкэндов и типов вывода, в связи с чем можно рассчитывать на его

работу независимо от того, какие операционные системы используются или какой формат вывода используется. Указанная библиотека обладает большой пользовательской базой и находится в активной разработке.

Перечисленные библиотеки являются мощными инструментами для реализации алгоритмов машинного обучения и анализа данных.

Моделирование изучаемых объектов и методы анализа данных

Связь между изучаемым объектом и вычислительным устройством может быть представлена схемой (рис. 2).

Согласно рис. 2, определение объекта решения предшествует поиску способа решения задачи, а первостепенное значение приобретает построение математической модели, обладающей различными свойствами. В некоторых случаях модель может остаться не доопределенной. После синтеза модели может быть разработан алгоритм, предписывающий четкую последовательность действий и разделяющий параметры на входные и выходные, явным образом определяя вторые через первые. Отметим, что каждая функция (рис. 2) может быть реализована множеством разных алгоритмов. Достаточно большое число алгоритмов для анализа изучаемых объектов основаны на применении метода главных компонент [2].




Рис. 2. Связь между реальным объектом и вычислительным устройством

Метод главных компонент, или PCA (англ Principal Component Analysis) является одним из методов многомерного статистического анализа. Цель PCA заключается в сокращении размерности объема признаков при минимальной потере полезной информации. Еще в 1901 году этот метод был представлен К. Пирсоном. Позже его детально проработал американский экономист и статистик Г. Хоттелинг.




Рис. 3. Иллюстрация метода главных компонент

С математической точки зрения метод PCA основывается на таком линейном преобразовании евклидова пространства, которое сохраняет длины или скалярное произведение векторов, или на ортогональном линейном преобразовании. Это преобразование должно отображать данные первичного объема признаков в новом объеме меньшей размерности. Для этого нужно построить первую ось новой системы координат так, чтобы дисперсия D данных вдоль нее приобрела максимальное значение. Вторую ось строят

перпендикулярно первой так, чтобы дисперсия D данных вдоль нее была максимальной из оставшихся возможных и т.д. Поэтому первую ось называют первой главной компонентой, вторую – второй и т.д. Метод проиллюстрирован на рис. 3.

На рис. 3 показано снижение размерности исходного двумерного пространства (x_1, x_2) с помощью метода главных компонент до одномерного. Первая главная компонента ориентирована вдоль направления наибольшей вытянутости эллипсоида рассеяния точек объектов исходного набора данных в пространстве признаков, т.е. с ней связана наибольшая дисперсия. Таким образом, смысл метода заключается в том, что с каждой главной компонентой связана определенная доля общей дисперсии исходного набора данных.

Метод главных компонент – наиболее известный метод сокращения размерности, который применяется для широкого круга областей и задач (рис. 4).

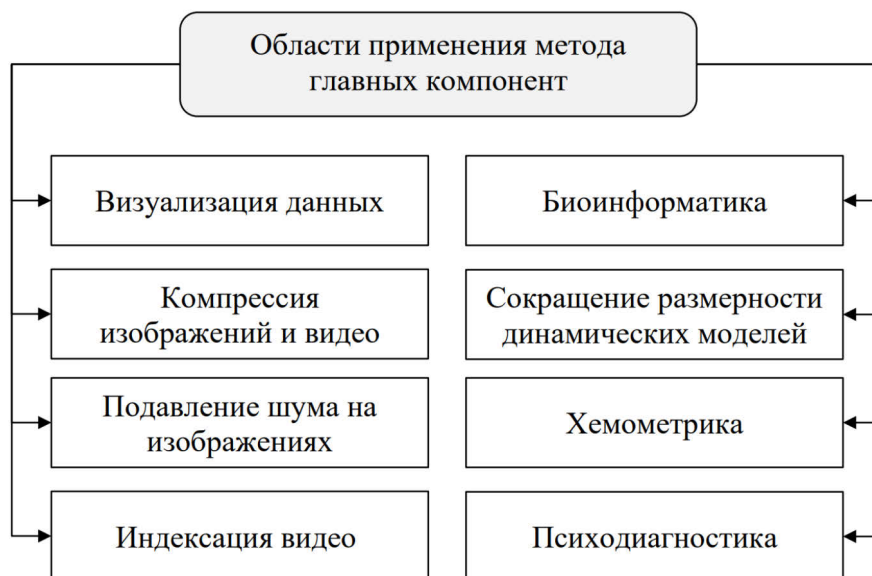


Рис. 4. Области применения метода главных компонент

Сокращение размерности динамических моделей часто используется при построении и анализе математических моделей, описываемых различными типами многомерных дифференциальных уравнений [1].

Основными целями понижения размерности являются:

- визуализация многомерных данных в двухмерном или трехмерном пространстве
- уменьшение затрат на ресурсы
- снижение уровня шума в данных.

Снижение шума в данных может служить для подготовки набора данных при обучении различных типов НС.

Важно отметить, что при построении нейросетевых алгоритмов существенное значение имеют вопросы интеллектуального анализа данных и понижения их размерности. В настоящей работе мы рассматриваем подход к анализу набора данных на основе конструкции «Ирисы Фишера» [9].

Анализ с использованием набора данных «Ирисы Фишера»

Метод главных компонент используется в задачах понижения размерностей путем линейного регрессионного анализа, а также позволяет производить дискриминационный анализ данных, благодаря чему возможно построение модели на основе существующего набора данных особой структуры. Кроме того, возможно сочетание метода главных компонент с методами машинного обучения [10].

Машинное обучение позволяет научить компьютеры самостоятельно принимать решения, чтобы автоматизировать выполнение определенных задач. По этой причине машинное обучение применяется во многих областях, среди которых есть и наука о данных.

В качестве примера приведем интеллектуальный анализ данных и рассмотрим подход к построению НС с применением набора данных «Ирисы Фишера» [9]. «Ирисы Фишера» – набор данных, часто используемый для иллюстрации работы различных алгоритмов классификации. Набор данных «Ирисы Фишера» составлен из 3 видов цветов ириса (Setosa – 1, Versicolour – 2 и Virginica – 3) с 4 атрибутами: длиной чашелистика, шириной чашелистика, длиной лепестка и шириной лепестка. Анализ основных компонентов, применяемый к этим данным, определяет комбинацию атрибутов (основных компонентов или направлений в пространстве функций), которые составляют наибольшую дисперсию данных. Теперь задача о классификации ирисов может быть достаточно легко формализована: нам нужно найти такую функцию от четырёх независимых переменных, чтобы она предсказывала вид ириса с минимальной ошибкой. Под ошибкой понимается неверное определение вида ириса. Искомые параметры мы можем задать в виде следующих переменных (таблица 1).

Таблица 1.

Переменные для функции определения типа цветка ирисов Фишера

sepalLength	sepalWidth	petalLength	petalWidth	irisType
Длина чашелистика	Ширина чашелистика	Длина лепестка	Ширина лепестка	Тип Ириса

В таком случае получаем функцию следующего вида

$$f(\text{sepalLength}, \text{sepalWidth}, \text{petalLength}, \text{petalWidth}) = [\text{irisType}]$$

где

$$\text{irisType} = [\text{setosa}|\text{versicolor}|\text{virginica}]$$

в зависимости от выходного набора. Алгоритм для нейронной сети состоит из следующих шагов.

Шаг 1. Передать данные на входные слои.

Шаг 2. Обработать с помощью скрытого слоя.

Шаг 3. Обработка в первом выходном слое по типу Setosa.

Шаг 4. Обработка во втором выходном слое по типу Versicolour.

Шаг 5. Обработка в третьем выходном слое по типу Virginica.

Таблица 2.

Данные для обучающего набора

	SEPALLEN	SEPALWID	PETALLEN	PETALWID	IRISTYPE
1	5,0	3,3	1,4	0,2	SETOSA
2	6,4	2,8	5,6	2,2	VIRGINIC
3	6,5	2,8	4,6	1,5	VERSICOL
4	6,7	3,1	5,6	2,4	VIRGINIC
5	6,3	2,8	5,1	1,5	VIRGINIC
6	4,6	3,4	1,4	0,3	SETOSA
...
127	6,5	3,2	5,1	2,0	VIRGINIC
128	6,1	2,9	4,7	1,4	VERSICOL
129	5,6	2,9	3,6	1,3	VERSICOL
130	5,0	2,3	3,3	1,0	VERSICOL

Для выполнения данного алгоритма необходимо подать на вход нейронной сети 130 реализаций из файла исходных данных, перемешанных случайным образом. Пример такого обучающего набора можем представить в следующем виде (таблица 2).

В качестве тестового (testing) набора далее предъявим сети 10 случайно отобранных реализаций, не включенных в обучающий набор. Представим пример тестового набора данных (таблица 3). Оставшиеся 10 случайно отобранных реализаций, не включенных в обучающий набор, нужно предъявить обученной сети для распознавания.

Таблица 3.

Данные, не включенные в обучающий набор

1	6,9	3,1	4,9	1,5	VERSIKOL
2	6,4	2,7	5,3	1,9	VIRGINIC
3	6,8	3,0	5,5	2,1	VIRGINIC
4	5,5	2,5	4,0	1,3	VERSIKOL
5	4,8	3,4	1,6	0,2	SETOSA
6	4,8	3,0	1,4	0,1	SETOSA
7	4,5	2,3	1,3	0,3	SETOSA
8	5,7	2,5	5,0	2,0	VIRGINIC
9	5,7	3,8	1,7	0,3	SETOSA
10	5,1	3,8	1,5	0,3	SETOSA

Пример интеллектуального анализа с применением набора данных «Ирисы Фишера» представлен на рис. 5.




Рис. 5. Результат интеллектуального анализа данных с применением набора данных «Ирисы Фишера»

Задачи дискриминационного анализа, аналогичные рассмотренной задаче, могут возникать при решении проблем машинного обучения. Дискриминационный анализ данных может использоваться при статистическом подходе к решению задач классификации в различных прикладных областях.

Описанный в настоящей работе подход к анализу данных планируется применить для изучения моделей технических систем с переключениями [4, 8], в частности, для настройки различных типов регуляторов при построении управляющих функций, согласованных с критериями качества управления.

Заключение

Развитие технологий машинного обучения и прогресс в разработке методик автоматизированного поиска способов построения эффективных обучающихся моделей анализа данных способствуют решению многих практических задач искусственного интеллекта. На основе проведенного исследования можно сделать вывод о том, что использование метода главных компонент в качестве способа обработки входных данных является эффективным и улучшает качественные характеристики модели искусственной нейронной сети. Изученная взаимосвязь организации набора данных «Ирисы Фишера» с использованием различных типов нейросетей позволит усовершенствовать методы настройки нейросетевых регуляторов при моделировании динамических систем.

Перспективами дальнейших исследований является разработка алгоритмического обеспечения для решения задач классификации, регрессии и прогнозирования, а также анализ перспективных конструкций наборов данных для использования при построении нейросетевых алгоритмов.

Список литературы

1. Айвазян С.А., Бухштабер В.М., Енюков И.С., Мешалкин Л.Д. Прикладная статистика. Классификация и снижение размерности. М.: Финансы и статистика, 1989. 607 с.
2. Айвазян С.А., Енюков И.С., Мешалкин Л.Д. Прикладная статистика: Основы моделирования и первичная обработка данных. М.: Финансы и статистика, 1983. 472 с.
3. Васильев А. Н., Тархов Д. А. Принципы и техника нейросетевого моделирования. М.: Нестор-История, 2014. - 218 с.
4. Дружинина О.В., Корепанов Э.Р., Белоусов В.В., Масина О.Н., Петров А.А. Опыт разработки методов и средств нейросетевого моделирования нелинейных систем на базе отечественной вычислительной платформы "Эльбрус 801-РС" // Нелинейный мир. 2020. Т. 18. №2. С. 5-17.
5. Круглов В.В., Дли М.Н., Голунов Р.Ю. Нечеткая логика и искусственные нейронные сети. М.: Физматлит, 2001. 201 с.
6. Слепцов А.Ф., Слепцова М.В. Интеллектуальная образовательная среда: теоретические подходы и возможности реализации // Современные исследования социальных проблем (электронный научный журнал). 2016. № 5. С. 70-88.
7. Хайкин С. Нейронные сети. М.: Издательский дом "Вильямс", 2006. 1104 с.
8. Druzhinina O.V., Masina O.N., Petrov A.A., Lisovsky E.V., Lyudagovskaya M.A. Neural Network Optimization Algorithms for Controlled Switching Systems // Advances in Intelligent Systems and Computing (AISC). 2020. V. 1225. P. 470-483.
9. Fisher, R.A. The Use of Multiple Measurements in Taxonomic Problems // Annals of Eugenics. 1936. Vol. 7. P. 179 -188.
10. Gorban A.N., A. Zinovyev. Principal manifolds and graphs in practice: from molecular biology to dynamical systems, International Journal of Neural Systems, Vol. 20, No. 3 (2010) 219-232.
11. Plotnikova N.P., Fedosin S.A., Teslya V.V. Gravitation search training algorithm for asynchronous distributed multilayer perceptron model // Lecture Notes in Electrical Engineering. 2015. V. 312. P. 417-423.

APPROACH TO DATA MODELING AND ANALYSIS BASED ON THE DEVELOPMENT OF MACHINE LEARNING ALGORITHMS

S.V. Chernomordov

postgraduate student
Chernomor96@list.ru
Yelets

Bunin Yelets State University

D.Y. Openkin

postgraduate student
openkin.study@mail.ru
Yelets

Abstract. An urgent problem is to develop approaches to data modeling and analysis based on intelligent algorithms. This paper deals with the construction and analysis of mathematical models of dynamic systems with intelligent components. The application of the principal component method for solving machine learning problems, in particular, for solving the regression problem, is considered. Examples of data mining using the Fischer Irises dataset are analyzed.

Keywords: data mining, Fischer's Irises dataset, Python, principal component analysis, machine learning.

References

1. Ayvazyan, S.A., Enyukov, I.S., Meshalkin, L.D. (1983). *Prikladnaya statistika: Osnovy modelirovaniya i pervichnaya obrabotka dannyh* [Applied statistics: Basics of modeling and primary data processing]. Moscow: finance and statistics. (In Russ.)
2. Ayvazyan, S. A., Bukhshtaber, V. M., Enyukov, I. S., Meshalkin, L. D. (1989). *Prikladnaya statistika. Klassifikaciya i snizhenie razmernosti* [Applied statistics. Classification and dimension reduction]. Moscow: Finance and statistics. (In Russ.)
3. Druzhinina, O.V., Korepanov, E. R., Belousov, V.V., Masina, O.N., Petrov, A.A. (2020). *Opyt razrabotki metodov i sredstv nejrosetevogo modelirovaniya nelinejnyh sistem na baze otechestvennoj vychislitel'noj platformy «El'brus 801-PC»* [Experience in the development of methods and tools for neural network modeling of nonlinear systems based on the domestic computing platform «Elbrus 801-PC»]. *Nonlinear world*, 18 (2), 5-17. (In Russ.)
4. Druzhinina, O.V., Masina, O.N., Petrov, A.A., Lisovsky, E.V., Lyudagovskaya, M.A. (2020). Neural Network Optimization Algorithms for Controlled Switching Systems. *Advances in Intelligent Systems and Computing (AISC)*, 1225, 470–483.
5. Fisher, R.A. (1936). The Use of Multiple Measurements in Taxonomic Problems [Ispol'zovanie mnozhestvennyh izmerenij v taksonomicheskikh zadachah]. *Annals of Eugenics*, 7, 179–188.
6. Gorban, A.N., Zinovyev, A. (2010). Principal manifolds and graphs in practice: from molecular biology to dynamical systems. *International Journal of Neural Systems*, 20(3), 219-232.
7. Haykin, S. (2006). *Nejronnye seti* [Neural networks]. Moscow: Publishing house «Williams». (In Russ.)
8. Kruglov, V.V., Dli, M.N., Golunov, R.Yu. (2001). *Nechetkaya logika i iskusstvennye nejronnye seti* [Fuzzy logic and artificial neural networks]. Moscow: Fizmatlit. (in Russ.)
9. Plotnikova, N.P., Fedosin, S.A., Teslya, V.V. (2015). Gravitation search training algorithm for asynchronous distributed multilayer perceptron model. *Lecture Notes in Electrical Engineering*, 312, 417-423.

10. Sleptsov, A.F., Sleptsova, M.V. (2016) *Intellectual'naya obrazovatel'naya sreda: teoreticheskie podhody i vozmozhnosti realizacii. Modern studies of social problems (electronic scientific journal)*, 5, 70-88.
11. Vasiliev, A.N., Tarkhov, D.A. (2014) *Principy i tekhnika nejrosetevogo modelirovaniya* [Principles and techniques of neural network modeling]. Moscow: Nestor-History. (In Russ.)