

Журнал зарегистрирован Федеральной службой по надзору в сфере связи, информационных технологий и массовых коммуникаций (Роскомнадзор)

Свидетельство о регистрации
ПИ № ФС77-64098
от 18 декабря 2015 г.

Учредитель – Федеральное государственное бюджетное образовательное учреждение высшего образования «Технологический университет имени дважды Героя Советского Союза, летчика-космонавта А.А. Леонова» (141074, Московская область, г. Королев, ул. Гагарина, д. 42)
Издается с сентября 2014 г.
Выходит 4 раза в год

ISSN 2409-1650

Журнал «Информационно-технологический вестник» включён в Перечень ведущих периодических изданий ВАК

Группы научных специальностей и научные специальности в рамках групп научных специальностей, по которым издание входит в Перечень:
2. Технические науки; 2.2. Электроника, фотоника, приборостроение и связь; 2.3. Информационные технологии и телекоммуникации [2.3.1. Системный анализ, управление и обработка информации; 2.3.5. Математическое и программное обеспечение вычислительных систем, комплексов и компьютерных сетей]; 2.5. Машиностроение [2.5.13. Проектирование, конструкция и производство летательных аппаратов]; 2.6. Химические технологии, науки о материалах, металлургия; [2.6.17. Материаловедение]

Подписной индекс в каталоге «Почта России» ПП1997

Главный редактор
Артюшенко Владимир Михайлович,
д.т.н., профессор

Над выпуском работали
Паршина Ю.С.
Пирогова Е.В.

Адрес редакции:
141070, Королев,
Ул. Октябрьская, 10а
Тел. (495)543-34-31 (доб.138),
E-mail: rio-kimes@mail.ru,
Site: www.unitech-mo.ru

Редакция не несет ответственности за достоверность информации в материалах, в том числе рекламных, представленных авторами для публикации
Материалы приводятся в авторской редакции.

СОДЕРЖАНИЕ

СИСТЕМНЫЙ АНАЛИЗ, УПРАВЛЕНИЕ И ОБРАБОТКА ИНФОРМАЦИИ

Вальс В.И.
АНАЛИЗ ИСПОЛЬЗОВАНИЯ МОДУЛЯ ПРЕОБРАЗОВАНИЯ ТАБЛИЦ VISUAL FOXPRO В ФОРМАТ SQL DUMP В СИСТЕМАХ ДОКУМЕНТООБОРОТА.....3

Лукьянов А.А.
АНАЛИЗ МЕТОДОЛОГИЙ И ИНСТРУМЕНТО В НЕПРЕРЫВНОЙ ИНТЕГРАЦИИ И ПОСТАВКИ ДЛЯ ПОВЫШЕНИЯ ЭФФЕКТИВНОСТИ СБОРКИ ЗАГРУЗОЧНОЙ СРЕДЫ LINUX ДЛЯ ВСТРАИВАЕМЫХ СИСТЕМ УДАЛЁННОГО ДОСТУПА.....15

Филяев Г.А., Релич С.Т.
НЕПАРАМЕТРИЧЕСКАЯ И МОДЕЛИРУЕМАЯ НАДЕЖНОСТЬ КОСМИЧЕСКИХ ЛЕТАТЕЛЬНЫХ АППАРАТОВ.....26

МАТЕМАТИЧЕСКОЕ И ПРОГРАММНОЕ ОБЕСПЕЧЕНИЕ ВЫЧИСЛИТЕЛЬНЫХ СИСТЕМ, КОМПЛЕКСОВ И КОМПЬЮТЕРНЫХ СЕТЕЙ

Жаров В.Г., Шайтура С.В., Останкова Н.В.
ЭКОНОМИКО-МАТЕМАТИЧЕСКАЯ МОДЕЛЬ ИНФРАСТРУКТУРЫ СЕРВИСА.....39

Семенов А.Б., Артюшенко В.М.
ОСОБЕННОСТИ ПРОЯВЛЕНИЯ СИСТЕМНОЙ ПРОБЛЕМЫ СЛАБОГО ЗВЕНА В ТЕХНИКЕ СТРУКТУРИРОВАННОГО КАБЛИРОВАНИЯ.....66

Шульженко Н.А., Шульженко С.Н.
КОРРЕЛЯЦИОННАЯ ЗАВИСИМОСТЬ ПОДСИСТЕМ ИННОВАЦИОННОГО РАЗВИТИЯ ПРЕДПРИЯТИЙ С УЧЕТОМ ОСОБЕННОСТЕЙ ИХ КОРПОРАТИВНОГО ВЗАИМОДЕЙСТВИЯ НА ОТРАСЛЕВОМ И РЕГИОНАЛЬНОМ УРОВНЕ.....77

ПРОЕКТИРОВАНИЕ, КОНСТРУКЦИЯ И ПРОИЗВОДСТВО ЛЕТАТЕЛЬНЫХ АППАРАТОВ

Аббасова Т.С., Мудрецов А.В.
МОДЕЛИ И МЕТОДЫ МАШИННОГО ОБУЧЕНИЯ ДЛЯ АНАЛИЗА ДАННЫХ О КОСМИЧЕСКИХ ОБЪЕКТАХ.....94

УДК 004.021

**Модели и методы машинного обучения для анализа данных
о космических объектах**

Татьяна Сергеевна Аббасова, кандидат технических наук,
доцент кафедры информационных технологий и управляющих систем,
Артём Вадимович Мудрецов, аспирант кафедры информационных технологий
и управляющих систем,
Федеральное государственное бюджетное образовательное учреждение
высшего образования
«Технологический университет имени дважды Героя Советского Союза,
летчика-космонавта А.А. Леонова», г. Королев, Московская область

Проанализированы возможности применения моделей и методов машинного обучения при решении задачи минимизации эмпирического риска в исследованиях космических объектов; определены аналитические зависимости, раскрывающие механизм действия алгоритмов оптимизации анализа и обработки больших данных о космических объектах; показаны наиболее частые приемы, используемые для сокращения вычислений и минимизации ошибок при вычислениях.

Машинное обучение, анализ данных, стохастическая оптимизация, градиентный спуск, задача классификации.

**Models and methods of machine learning for the analysis of data on space
objects**

Tatyana Sergeevna Abbasova, Candidate of technical Sciences, Associate Professor,
Artyom Vadimovich Mudretsov, postgraduate student of the Department
of Information Technologies and Control Systems,
Federal State Budgetary Educational Institution of Higher Education
«Technological University named after twice Hero of the Soviet Union,
pilot-cosmonaut A.A. Leonov», Korolev, Moscow region

The possibilities of using models and methods of machine learning in solving the problem of minimizing empirical risk in the study of space objects are analyzed; analytical dependencies are determined that reveal the mechanism of action of algorithms for optimizing the analysis and processing of big data on space objects; shows the most common tricks used to reduce calculations and minimize errors in calculations.

Machine learning, data analysis, stochastic optimization, gradient descent, classification task.

Введение

С 1994 года для исследования космоса широко применяется машинное обучение, так как необходимо анализировать и обрабатывать большое количество данных о космических объектах, к которым предъявляются требования автономности [2, С. 58; 3, С. 50]. Автономность реализуется посредством интеллектуальных систем управления [7, С. 77], в которые входят роботы-помощники, голосовые помощники [1, С. 85], средства распознавания и улучшения полученных в результате дистанционного зондирования изображений, 3D-принтеры для печати запасных частей космических аппаратов и многие другие интеллектуальные устройства [4, С. 21; 5, С. 20].

В машинном обучении применяется градиентный спуск – это алгоритм оптимизации, используемый для минимизации ошибок в модели машинного обучения. Он работает путем итеративной корректировки параметров модели в направлении отрицательного градиента функции потерь (которая представляет ошибку), чтобы уменьшить ошибку и найти оптимальные параметры, которые дают наилучшие результаты прогнозирования. Алгоритм продолжает этот процесс до тех пор, пока он не достигнет минимума или не будет выполнен заранее определенный критерий остановки. Особую актуальность алгоритм градиентного спуска приобретает для обработки большого объема данных при космических исследованиях.

Результаты исследования

Задача минимизации эмпирического риска

Рассмотрим задачи минимизации эмпирического риска на примере задачи регрессии [6, С. 15]. Затем рассмотрим метод стохастического градиента. Предположим, что существует следующая обучающая выборка в виде конечного множества l штук пар космический объект-ответ:

$$X^l = (x_i, y_i)_{i=1}^l, \quad (1)$$

где $x_i \in R^n$ – означает, что космический объект описывается n числовыми признаками; $y_i \in R$ – числовой ответ.

В обучающей выборке указано, что каждому объекту x_i соответствует правильный ответ y_i . Фиксируем модель, с помощью которой рассчитываем предсказывать y_i по вектору x_i . В общем случае это некоторое параметрическое семейство функций $a(x, w)$

$$a(x, w) = \sum_{j=1}^n w_j f_j(x); \quad w \in R^n. \quad (2)$$

Сделаем предположение, что данная модель – линейная и является взвешенной суммой признаков $f_j(x)$ с некоторыми весовыми коэффициентами w_j . Другими словами, функция a есть скалярное произведение двух векторов: x (признаковое описание объектов x) и w (вектор весовых коэффициентов линейной модели). Следующий шаг – фиксация функции потерь (предположим, что данная функция является квадратичной):

$$L(a, y) = (a - y)^2. \quad (3)$$

Данная функция потерь сравнивает правильный ответ y с ответом a , который выдает модель. Чем меньше квадрат разности – тем меньше потери. Если взять такую функцию потерь и просуммировать все потери на объектах обучающей выборки (при том, что на объекте x_i используется модель, которая зависит от параметра), то будет сконструирован особый функционал. Это числовая функция от вектора w . И теперь появляются критерии качества, по которым возможно найти w минимизируя этот критерий. Другими словами, ставится оптимизационная задача на данном этапе. Далее эту задачу необходимо решать с помощью известных численных методов. В данной статье рассмотрен численный метод оптимизации первого порядка (так называемые градиентный метод) с тем отличием, что используется не типовая оптимизация, а машинное обучение. Это означает, что если мы модель построена по обучающей выборке, то обязательно ее необходимо проверить на отлаженных тестовых данных или сделать «скользящий» контроль или еще что-то сделать, чтобы проверить насколько модель действительно обладает «предсказательной силой». Например, рассчитаем среднюю ошибку $\bar{Q}(w)$ построенной модели на новых объектах

$$X^k = (\tilde{x}_i, \tilde{y}_i)_{i=1}^k, \quad (4)$$

$$\bar{Q}(w) = \frac{1}{k} \sum_{i=1}^k (a(\tilde{x}_i, w) - \tilde{y}_i)^2, \quad (5)$$

где \tilde{x}_i – известные объекты; \tilde{y}_i – известные ответы.

Для того чтобы иметь k таких объектов, необходимо иметь $l+k$ объектов с известными правильными ответами. Для решения задачи берется полная выборка, разделяется на две части. На первой части происходит обучение.

$$Q(w) = \sum_{i=1}^l (a(x_i, w) - y_i)^2 \rightarrow \min_w. \quad (6)$$

На второй части необходимо проверить, насколько модель переобучена. Представляет особый интерес сравнить среднюю ошибку на обучении и среднюю ошибку на контроле. На нем эта ошибка несколько больше: если незначительно больше, то модель не сильно переобучена. Если ошибка во много раз больше, то модель не подходит для решения этой задачи и необходимо менять модель.

Обучение классификации тоже является задачей оптимизации. Рассмотрим задачу классификации на 2 класса. Существует обучающая выборка, объекты (в том числе космические) описываются n числовыми признаками

$$X^l = (x_i, y_i)_{i=1}^l, \quad (7)$$

где $x_i \in R^n$ – означает, что объект описывается n числовыми признаками;

$y_i \in \{-1, +1\}$ – бинарный ответ.

Составим линейную модель. Для этого составим скалярное произведение между вектором признаков описания нашего объекта и вектором параметров

$$a(x, w) = \text{sign}\langle x, w \rangle = \text{sign} \sum_{j=1}^n w_j f_j(x). \quad (8)$$

Однако теперь интерес представляет знак этого скалярного произведения. Это означает, что в пространстве R^n строится разделяющая гиперплоскость. Она имеет направляющий вектор w . Если объект попал в ту самую половину пространства, куда направлен вектор w , то это класс $+1$. Другими словами, угол между вектором x и вектором w острый. В случае если угол тупой, то скалярное произведение отрицательно и объекты соотносятся классу -1 .

Итак, линейные модели для классификации подходят поскольку они определяют разделяющую гиперплоскость пространства R^n .

Следующий шаг – это определить потери. Для задачи классификации функция потерь L определяет ошибку. Правильный ответ y и тот ответ, который дала нам модель a есть либо $+1$, либо -1 . Если они разного знака, то это ошибка. В данном случае функция потерь бинарная (ее аппроксимация $L(\langle x, w \rangle y)$).

$$L(a, y) = [ay < 0] = [\langle x, w \rangle y < 0] \leq L(\langle x, w \rangle y). \quad (9)$$

Для проверки знака возьмем произведение ay (обе величины дискретные и их значения: $+1$ либо -1)

$$[ay < 0], \quad (10)$$

где a это знак $\text{sign}\langle x, w \rangle$. Если убрать данную функцию (sign), то определение ошибки не изменится. Существует особенность: если данной функцией потерь $[\langle x, w \rangle y < 0]$ организовать функционал $Q(w)$, то это функционал будет неподходящим для решения оптимизационной задачи, поскольку он принимает $l + 1$ дискретное значение.

$$Q(w) = \sum_{i=1}^l [\langle x_i, w \rangle y_i < 0] \leq \sum_{i=1}^l L(\langle x_i, w \rangle y_i) \rightarrow \min_w. \quad (11)$$

В (11) представлен дискретный функционал, следовательно, требуется минимизация дискретного функционала. Данная задача комбинаторной оптимизации и достаточно трудная для решения. Для обхода этой проблемы используется следующий метод: подмена пороговой функции потерь непрерывной функцией (для того, чтобы иметь возможность пользоваться градиентными методами и использовать непрерывную оптимизацию, вместо дискретной). Предположим, что существует бинарная функция потерь $[\langle x, w \rangle y < 0]$. В ней значение $\langle x, w \rangle y$ отрицательно, итоговая функция равна 1.

Предлагается замена $[\langle x, w \rangle y < 0]$ некоторой непрерывной оценкой сверху. Обозначим ее как

$$L(\langle x, w \rangle y). \quad (11)$$

Чем больше значение $\langle x, w \rangle y$, тем меньше потери. Отсюда проистекают следующие требования для функции L : непрерывная (лучше гладкая убывающая функция). Если была заменена бинарная функция потерь на непрерывную гладкую, то появилась возможность решать непрерывную гладкую задачу минимизации верхней оценки исходного функционала. Другими словами, произойдет приближенная минимизация числа ошибок. В задаче машинного обучения должна быть тестовая выборка X^k , на которой следует проверять «предсказательную силу» модели.

$$X^k = (\tilde{x}_i, \tilde{y}_i)_{i=1}^k, \quad (12)$$

$$\bar{Q}(w) = \frac{1}{k} \sum_{i=1}^k [\langle \tilde{x}_i, w \rangle \tilde{y}_i < 0]. \quad (13)$$

Понятие допуска для разделяющих классификаторов

Рассмотрим классификатор, основанный на принципе «дискриминации». Происходит построение разделяющей поверхности, графически этот процесс представлен на рисунке 1.

Разделяющий классификатор: $a(x, w) = \text{sign } g(x, w)$.

Если $a(x, w)$ – это скалярное произведение 2-х векторов, то строится гиперплоскость. Если $g(x, w)$ – неизвестная параметрическая функция, то строится нелинейная разделяющая поверхность.

Введем обозначения:

$g(x, w)$ – разделяющая (дискриминантная функция);

$g(x, w) = 0$ – уравнение разделяющей поверхности;

Тогда отступ (допуск) объекта x_i от разделяющей поверхности

$M_i(w) = g(x_i, w) y_i$.

$M_i(w) < 0$ – алгоритм $a(x, w)$ ошибается на x_i .




Рисунок 1 – Ранжирование объектов по возрастанию допусков

Геометрический смысл: отступ – это расстояние до разделяющей поверхности, взятое со знаком. Если ошибка, то знак отрицательный (положительный в случае отсутствия ошибки). На практике, когда решаются задачи классификации с помощью подобных дискриминантных моделей, возникает интерес узнать, как распределились отступы на объектах обучающей выборки по своим значениям и интерпретировать эти объекты. Например, если отступ большой величины и отрицательный, то это объект, который улетел в толщу чужого класса (рисунок 1). Данный объект далек от разделяющей поверхности и, возможно, это некий аномальный объект, который был некорректно измерен.

В случаях, когда отступ имеет высокое положительное значение то получается типичный «эталонный» объект своего класса. Пограничные зоны могут охарактеризовать качество построения модели. Особый интерес представляет сравнение кривой на объектах обучающей выборки и контрольной выборки и анализ насколько велика степень переобучения.

Часто используемые функции потерь показаны в таблице 1 (рассмотрены непрерывные функции).

Несмотря на разнообразие методов, все методы, так или иначе, сводятся к минимизации эмпирического риска, где функцию потерь взяли аналогичную указанным в таблице (таблица 1). Почти все представленные функции непрерывно монотонно убывающие (за исключением параболы, п. 4).

История машинного обучения – это история полная случаями, когда исследователи придумывали очень разные принципы классификации. Но спустя некоторое время оказалось, что они эквивалентны методам минимизации эмпирического риска лишь за исключением того, что требуется менять функцию потерь в зависимости от задачи.

Таблица 1 – Функции потерь

	Функция	Наименование
1	$V(M) = (1 - M)$	Кусочно-линейная (SVM)
2	$H(M) = (-M)$	Кусочно-линейная (Hebb's rule)
3	$L(M) = \log_2(1 + e^{-M})$	Логарифмическая (LR)
4	$Q(M) = (1 - M)^2$	Квадратичная (FLD)
5	$S(M) = \frac{2}{1 + e^M}$	Сигмоидная (ANN)
6	$E(M) = e^{-M}$	Экспоненциальная (AdaBost)
7	$[M < 0]$	Пороговая функция потерь

Данный метод оказался очень эффективным: изменяя функцию потерь, можно получать те или иные методы классификации.

Модель нейрона

Также применяется математический нейрон Мак-Каллока-Питтса, формальный нейрон (простейшая модель функционирования нервной клетки – нейрона)

$$a(x, w) = \sigma(\langle w, x \rangle) = \sigma(\sum_{j=1}^n w_j f_j(x) - w_0), \quad (14)$$

где $\sigma(z)$ – функция активации (например, sign); w_j – весовые коэффициенты синаптических связей; w_0 – порог активации.

Схема формального нейрона приведена на рисунке 2.

Нервная клетка в первом приближении – это «черный ящик», у которого множество входов и один выход. «Черный ящик» выполняет функцию суммирования своих входов, помноженных на весовые коэффициенты. Эти коэффициенты являются свойствами самой клетки.

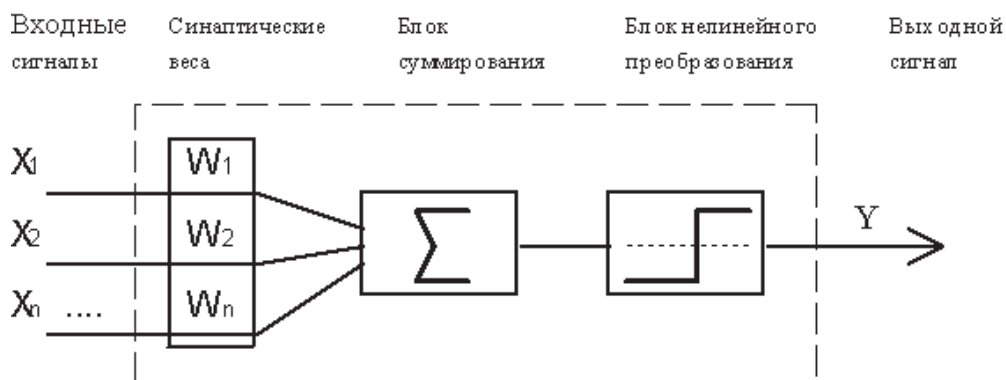


Рисунок 2 – Формальный нейрон

Модель Мак-Каллока-Питтса является первой формальной моделью нейронных сетей (НС) была, затем она была уточнена и развита ученым Клини. В реальной жизни нейроны классифицированы и устроены гораздо сложнее. Однако данная простейшая модель подтолкнула к созданию искусственных нейронных сетей.

Метод стохастического градиента

Это оптимизационный алгоритм, отличающийся от обычного градиентного спуска тем, что градиент оптимизируемой функции считается на каждом шаге не как сумма градиентов от каждого элемента выборки, а как градиент от одного, случайно выбранного элемента.

Минимизация эмпирического риска

$$Q(w) = \sum_{i=1}^l L_i(w) \rightarrow \min_w. \quad (15)$$

Численная минимизация методом стохастического градиентного спуска. Через L_i коротко обозначим функцию потерь на этом объекте. Запись L_i предполагает абстрагирование от того, как устроена модель и функция потерь.

Сущность градиентного метода оптимизации. В каждой точке можем посчитать вектор частных производных (градиент). Он показывает направление наибольшего возрастания функции в данной точке. Требуется минимизация, значит необходимо идти не по градиенту, а в противоположном направлении.

Начнем приближение с $w^{(0)}$. Далее каждое следующее приближение вычисляется как текущее приближение за вычетом градиента: $w^{(t+1)} = w^{(t)} - h\nabla Q(w^{(t)})$ – значение на шаге $t+1$.

Затем следует рассчитать следующую сумму

$$w^{(t+1)} = w^{(t)} - h \sum_{i=1}^l \nabla L_i(w^{(t)}). \quad (16)$$

Градиентный метод требует посчитать сумму по всем объектам обучающей выборки, сложить все эти градиенты и сместится в сторону «антиградиента» и получить новое приближение вектора $w^{(t+1)}$.

Если в этой сумме взять только часть слагаемых, то по закону больших чисел приближение будет достаточно хорошим. У этой идеи есть необычное предложение: использовать только одно слагаемое. Затем получим новое приближение для $w^{(t+1)}$. Следующие слагаемое в градиенте будем вычислять уже по другому случайному параметру $w^{(t)}$. Поскольку объекты берутся в случайном порядке, то смещение будет похоже на Броуновское и движение. При этом движение будет производиться в сторону направления скорейшего убывания функционала.

Геометрически метод стохастического градиентного спуска (SGD) изображен на рисунке 3.




Рисунок 3 – Стохастический градиентный спуск

Данная идея оказалась очень продуктивной, несмотря на то, что она выглядит очень простой и приводит к тому, что сходимость на самом деле ускоряется.

Алгоритм стохастического градиентного спуска (псевдокод)

Пример псевдокода (псевдоградиента) показан на рисунке 4.




Рисунок 4 – Псевдоградиент

$$\nabla \tilde{Q}(\omega^{(t)})$$

На рисунке 4 через $\nabla \tilde{Q}(\omega^{(t)})$ обозначен псевдоградиент.

Необходимо найти такой псевдоградиент, который позволил бы сократить объем вычислений для истинного градиента и при этом сохранить сходимость алгоритма к точке локального минимума.

Вход: выборка X^l , шаг обучения h , шаг забывания λ ;

Выход: весовые коэффициенты w ;

1. Инициализация $w_j, j=0, \dots, n$;
2. Инициализация: $\bar{Q} = \frac{1}{l} \sum_{i=1}^l L_i(w)$
3. Повтор
4. Выбрать случайный x_i из X^l
5. Определить погрешность $\varepsilon_i = L_i(w)$
6. Перейти на следующий шаг: $w = w - h \nabla L_i(w)$
7. Оценить $\bar{Q} = \lambda \varepsilon_i + (1 - \lambda) \bar{Q}$
8. Пока значение \bar{Q} и/или веса w не сойдутся.

Примечание к шагу № 7. Происходит модификация оценки функционала. Требуется найти какой-нибудь критерий остановки, поскольку необходимо следить за тем, как меняется функционал в процессе оптимизации. Далее в какой-то момент необходимо понять, что значение функционала перестало существенно меняться и остановить процесса. Для того чтобы возможно было остановить процесс потребуется значение функционала. Здесь возникает проблема: если функционал на каждом шаге вычислять точно, то это потребует суммирование по всем объектам обучающей выборки. Ранее было отмечено достижение увеличения эффективности алгоритма за счет того, что берутся объекты случайно. Те-

перь же предлагается выбрать все объекты и просуммировать их, что отменяет поученную ранее эффективность.

Существует специальный прием: предлагается оценивать экспоненциальное среднее потерь. Потери представляют собой $\varepsilon_i = L_i(w)$. Формула $\bar{Q} = \lambda\varepsilon_i + (1 - \lambda)\bar{Q}$ позволяет посчитать нечто среднее.

Приближенная рекуррентная формула:

Среднее арифметическое

$$\bar{Q}_M = \frac{1}{m}\varepsilon_m + \frac{1}{m}\varepsilon_{m-1} + \frac{1}{m}\varepsilon_{m-2} + \dots \quad (17)$$

$$\bar{Q}_M = \frac{1}{m}\varepsilon_m + \left(1 - \frac{1}{m}\right)\bar{Q}_{m-1}. \quad (18)$$

Экспоненциальное скользящее среднее

$$\bar{Q}_M = \lambda\varepsilon_m + (1 - \lambda)\lambda\varepsilon_{m-1} + (1 - \lambda)^2\lambda\varepsilon_{m-2} + \dots \quad (19)$$

$$\bar{Q}_M = \lambda\varepsilon_m + (1 - \lambda)\bar{Q}_{m-1}. \quad (20)$$

где λ – темп «стирания» предыстории ряда.

Это достаточно используемый прием для того, чтобы сократить вычисления, когда требуется посчитать некоторую величину подобно среднему (не имеет значения, это среднее арифметическое, усреднение по последним итерациям, усреднит по последним просмотренным элементам обучающей выборки и др.).

Машинное обучение имеет большое значение для управления космическим объектом, так как с помощью него можно решить следующие задачи: предсказать время опасного сближения; построить лучшие траектории уклонения; сформировать рекомендации манёвров космического объекта.

Программные средства реализации: симулятор для расчета положения и скорости космического объекта в любой момент времени по известным элементам орбиты на некоторый начальный момент времени; база данных для хранения информации об элементах орбиты всего рассматриваемого множества космических объектов (несколько тысяч); симулятор для расчета опасных ситуаций и маневров при опасном сближении космических объектов.

Заключение

Определены аналитические зависимости для оценки моделей и методов машинного обучения, используемых при анализе космических объектов и позволяющих сократить вычисления при обработке больших данных.

Литература

1. Аббасова Т.С. Интерактивный мобильный помощник для космического экипажа // Информационно-технологический вестник. 2023. № 1(35). С. 84-91.
2. Аббасова Т.С., Комраков А.А. Восстановление и проверка корректности телеметрических данных // Информационно-технологический вестник. № 2(04). 2015. С. 55-64.

3. Аббасова Т.С., Петровская З.В. Повышение оперативности обработки цифровой телеметрии в ракетно-технических системах // Информационно-технологический вестник. 2022. № 2(32). С. 49-56.
4. Аббасова Т.С., Погосян А.Т. Анализ структуры наземного комплекса управления космическими летательными аппаратами // Информационные технологии. Радиоэлектроника. Телекоммуникации (ITRT-2016): сб. статей VI международной заочной научно-технической конференции. Ч. 1 / Поволжский гос. ун-т сервиса. Тольятти: Изд-во: ПВГУС, 24-25.03.2016. С. 19-22 (345 с.).
5. Артюшенко В.М., Васильев Н.А., Аббасова Т.С. Комплекс полунатурного моделирования систем автоматического управления летательных аппаратов и ракетно-космической техники // Современные образовательные технологии, используемые в очном, заочном и дополнительном образовании / Сборник – Королев МО: Изд-во «Канцлер», Финансово-технологическая академия, ФТА, 2014. С. 17-22 (426 с.).
6. Васильев Ф.П. Методы оптимизации. М.: МЦНМО, 2011. 620 с.
7. Теодорович Н.Н., Ковалев И.И., Семенов А.Б. Оптимизация параметров оборудования перспективных многолучевых спутниковых систем // Информационно-технологический вестник. 2020. № 3(25). С. 75-87.