

УДК 51-72

КЛАССИФИКАЦИЯ ДЕТАЛЕЙ МЕТОДАМИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ПРИ ВЫБОРЕ МАТЕМАТИЧЕСКОЙ МОДЕЛИ РЕШЕНИЯ ЗАДАЧ ПЛАСТИЧЕСКОГО ТЕЧЕНИЯ

© 2025 Е. Н. Сосенушкин, Е. А. Яновская, А. С. Желнов

Московский государственный технологический университет «СТАНКИН», г. Москва, Россия

Статья поступила в редакцию 07.04.2025

Для выбора адекватной математической модели под конкретную задачу механики сплошной среды (МСС) часто приходится прибегать к классификаторам, которые позволяют разделить заготовки или детали по определенным признакам. Обычно рассматриваются конструктивные и/или технологические характеристики деталей. В качестве признаков могут быть выбраны функциональные, параметрические, конструктивные особенности этих деталей, включая геометрическую форму. В работе описывается возможность построения классификатора деталей методами искусственного интеллекта для дальнейшего использования классификатора при выборе математической модели для решения ряда задач МСС, в том числе задачи свободного течения в тонком слое или течения с наложением ограничений в одном или нескольких направлениях. Для компьютерного моделирования применяется метод машинного обучения нейронных сетей для отбора деталей по геометрическим признакам и объединения этих объектов в требуемую категорию, заложенную в алгоритме программы оператором. На основе такого «искусственного отбора» осуществляется создание процедуры общей классификации. В конце компьютерного моделирования была проведена верификация классификатора, разработанного с применением искусственного интеллекта, с помощью готовых 3D моделей и моделей, созданных генеративным нейросетевым алгоритмом. В предложенной работе рассматриваются этапы создания классификатора, его основные части и компьютерные методы моделирования, в том числе с использованием методов искусственного интеллекта.

Ключевые слова: искусственный интеллект; автоматическая классификация; машинное обучение; математическое моделирование

DOI: 10.37313/1990-5378-2025-27-2-170-179

EDN: IRHRGU

ОБРАЗ ДЕТАЛИ НА ОСНОВЕ ГЕОМЕТРИЧЕСКОГО ОПИСАНИЯ ФОРМЫ

Для решения нестационарных задач механики деформируемого твердого тела [1], требуется понимание того, какую математическую модель нужно выбрать в том или ином случае. Модели в свою очередь выбираются для конкретных деталей, форма которых определяет типовую технологию обработки заготовок давлением [2] и конструкцию штампового инструмента [3]. В силу широкого множества типов возможной геометрии деталей их принято классифицировать [4, 5]. При построении алгоритмов автоматической классификации [6] абстрагируются от самого объекта, требующего отнесения к какому-либо множеству сходственных объектов (классу), и оперируют образом объекта, составленным из совокупности признаков [7]. Условно признаки подразделяют на детерминированные, вероятностные и структурные [8]. На принципе общности конструктивно-технологических признаков построено большинство классификаторов машиностроительных деталей, в том числе поковок [5, 9]. В качестве примера приведем работы [10, 11], в которых на основе некоторых математических аналогов физических моделей строится система выбора штамповых материалов. В представляющей работе была поставлена цель создания автоматической системы классификации деталей, подлежащих изготовлению операциями пластического деформирования [12], основываясь на их геометрических формах. Известны подходы к объединению поковок в различные классы по общности технологии изготовления: плоскостные (односвязные, многосвязные) и пространственные (оболочки, объемные) [7]. Для создания классификатора требовались образы деталей, которые могут быть отображены чертежами, содержащими в общем виде три проекции, или заданные в виде 3D моделей.

Сосенушкин Евгений Николаевич, доктор технических наук, профессор кафедры систем пластического деформирования.
E-mail: sen@stankin.ru

Яновская Елена Александровна, кандидат технических наук, доцент кафедры прикладной математики.
E-mail: elena_yanovskaya@bc.ru

Желнов Андрей Сергеевич, преподаватель кафедры прикладной математики.
E-mail: a.zhelnov@stankin.ru

Проведем анализ информативности проекционных изображений на примере простых топологий: полая деталь (табл. 1, табл. 2) и фланец со стержнем (табл. 3, табл. 4) с разным сочетанием образующих внешнего и внутреннего контуров.

Для построения компьютерной классификации с возможностью автоматического распознавания [13] задаваемых деталей, формирования базы данных классифицируемых деталей [14] с построением единого классификатора, который в дальнейшем может быть использован для решения различных задач механики сплошной среды [15] с помощью аппарата математического моделирования, было принято решение использовать методы искусственного интеллекта [16].

Таблица 1. Возможные сочетания форм образующих элементов полых деталей

Форма внешней образующей	Форма внутренней образующей					
	△	□	○	□	□	○
△			+			
□				+		+
○				+		
□	+	+		+	+	
□						+
○		+				

Примечание: «+» - выборочные сочетания форм образующих, представленные в табл. 2

Таблица 2. Полые детали, заданные тремя видами изображений:
3D модель, вид сверху, осевое сечение

группа	Детали объемные полые			
	3D модель	Вид сверху	Разрез	
1	2	3	4	
1				
2				
3				
4				

Таблица 2. Полые детали, заданные тремя видами изображений: 3D модель, вид сверху, осевое сечение (окончание)

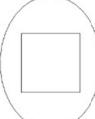
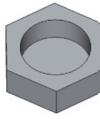
1	2	3	4
5			
6			
7			
8			

Таблица 3. Возможные сочетания форм образующих элементов стержневых деталей с фланцем

Форма фланца	Форма стержневой части				
					
				+	
		+			+
	+				
	+	+	+	+	
				+	

Примечание: «+» - выборочные сочетания форм образующих, представленные в табл. 4

МЕТОДЫ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ РАСПОЗНАВАНИЯ И КЛАССИФИКАЦИИ ДЕТАЛЕЙ

Под классификатором будем подразумевать компьютерную модель, которая может выполнять задачу оптимального распределения объектов по классам в соответствии со схожестью топологии. Существует множество вычислительных алгоритмов [17], которые могут быть использованы для классификации. Классификаторы в целом, можно разделить на две категории: классификаторы, основанные на определенных правилах, объединяемых продукционной системой [18] и классифи-

Таблица 4. Стержневые детали, заданные тремя видами изображений: 3D модель, вид сверху, фронтальный вид

Группа	Топология объемных деталей с фланцем и стержневой частью		
	3D модель	Вид сверху	Фронтальный вид
1	2	3	4
1			
2			
3			
4			
5			
6			
7			
8			
9			
10			

каторы, основанные на вычислительном эксперименте, в основе которого обычно заложены так называемые «мягкие» вычисления [19]. Классификаторы, основанные на правилах, обычно создаются разработчиком, который определяет правила интерпретации обнаруженных входных данных в отличие от классификаторов на основе «мягких» вычислений, в которых разработчик создает только базовые рамки для интерпретации данных. Алгоритмы машинного обучения [8, 14, 20] в таких системах отвечают за генерацию правил для корректной интерпретации данных.

Зачастую классификаторы, созданные с помощью искусственного интеллекта основаны на распознавании образов [7, 8, 13, 17] задаваемых объектов. Распознавание образов не ограничивается работой с двумерными изображениями, которые сканируются оптически. Речь идет о классе процедур, которые используются для обработки одномерных, двумерных и трехмерных сигналов, поступающих от любых датчиков. В качестве входных значений мы можем рассматривать любые данные, независимо от их происхождения – текст, звук, изображение и т. д., что говорит об универсальности подхода. В нашем случае компьютерные входные данные для описания геометрических форм задаваемых деталей могут быть представлены образами в виде набора логических и детерминированных различительных признаков, переведенных в двоичную форму без потери информативности и без ущерба общности. Здесь также следует отметить, что если вектор образа, формируемый для распознавания объектов, задан каким-то иным способом, отличающимся от двоичного представления, то распознавание образов приобретает гораздо более широкое значение для практических приложений.

Существует несколько методов искусственного интеллекта, которые могут быть использованы для решения задач классификации, в том числе:

- 1) Логистическая регрессия – статистический метод, используемый для прогнозирования бинарных исходов на основе набора входных переменных [21];
- 2) Деревья решений – иерархические модели, использующие древовидную структуру для принятия решений на основе входных переменных [22];
- 3) Случайные леса – метод, объединяющий несколько деревьев решений для получения более точных прогнозов [23];
- 4) Нейронные сети – алгоритм машинного обучения, в основе которого лежит структура и функции человеческого мозга [24];
- 5) Машины опорных векторов – алгоритм [25], который можно использовать как для классификации, так и для регрессионного анализа.

В представленной работе используется метод построения искусственной нейронной сети для распознавания и классификации задаваемых деталей с помощью глубокого обучения. Процесс обучения в глубоких сетях [26] опирается на два ключевых механизма: обратное распространение и градиентный спуск [27]. Обратное распространение вычисляет градиенты ошибок, а градиентный спуск использует эти градиенты для настройки весов сети. Таким образом, минимизируется выбранная функция потерь. Функции потерь в данном случае используются в оценке эффективности модели [28]. Они количественно оценивают разницу между прогнозируемым и фактическим выходом, направляя процесс оптимизации. Следует также отметить, что выбор функции потерь зависит от конкретной задачи классификации.

МОДЕЛИРОВАНИЕ КЛАССИФИКАЦИИ И РАЗРАБОТКА ГЕНЕРАТИВНЫХ МОДЕЛЕЙ С ПОМОЩЬЮ КОМПЬЮТЕРА

Для реализации системы классификации на базе машинного обучения было решено воспользоваться языком программирования *Python* [29]. Основным инструментом стал фреймворк *TensorFlow*, предоставляющий широкий спектр моделей и алгоритмов глубокого обучения. Эта библиотека позволяет работать с числовыми данными и создавать модели машинного обучения. Выбор *TensorFlow* был продиктован его универсальностью и возможностью адаптации архитектур. Первым шагом стала подготовка набора данных для классификации деталей, включающего 400 примеров с пятью признаками: наличием или отсутствием фланца, формой внутренних и внешних элементов, а также конфигурацией фланцевых частей. Эти данные были разделены на две группы: обучающую и тестовую. Генеративные модели машинного обучения [26] использовались для формирования обучающих наборов. Генератор не просто создает модели на основе случайных точек, но генерирует детали, основываясь на распределении, полученном во время обучения. Подобные подходы уже применялись в предыдущих исследованиях [30] и [31] при создании нейросетей для генерации рельефа поверхности. Этот метод применяется для создания новых данных на основе ключевых признаков объектов с использованием вероятностных моделей [32, 33]. Архитектура модели основана на одноточечном кодировании для целевых данных [34]. На выходе используются три нейрона. Схема применяемой сети изображена на рисунке 1.

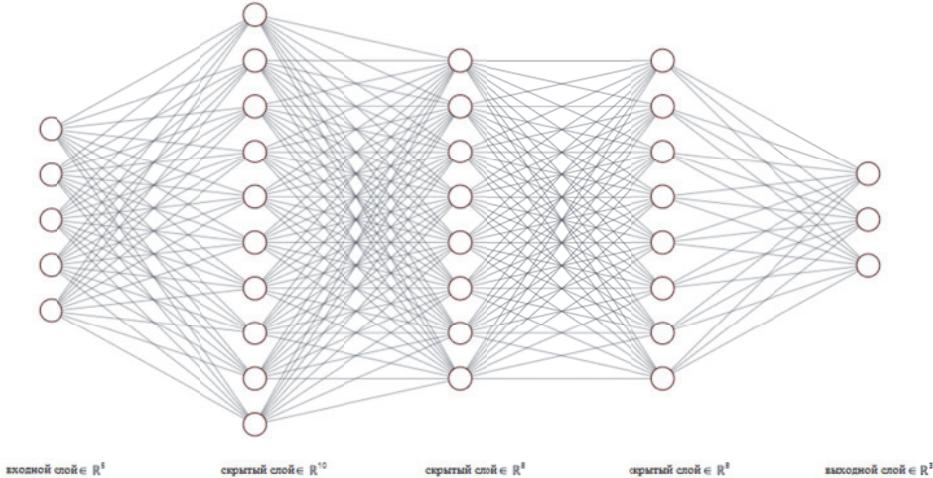


Рис. 1. Структура нейросетевой модели для классификации

В качестве функции потерь была выбрана перекрестная энтропия для количественной оценки разницы между двумя распределениями вероятностей [35]. Эта функция позволяет оценить, насколько хорошо функционирует модель классификации, сравнивая фактический и ожидаемый результаты. Математически функцию можно представить в виде:

$$C(p_t, p_p) = \sum_{i=1}^k p_t[i] \cdot \ln(p_p[i]), \quad (1)$$

где C – перекрестная энтропия, p_t – эталонная вероятность, p_p – вероятность каждого класса, k – количество классов. В предложенном алгоритме классификации значение перекрестной энтропии составило порядка $C=0,007$, что свидетельствует о схожести распределения друг относительно друга.

Кроме того, в некоторых случаях образуются расхождения с заранее заданной эталонной моделью, что усложняет определение класса. Математически эту задачу можно представить так: существует некоторый набор данных из пар (x_i, y_i) , в котором задан эталонный ответ y_i , являющийся неточным значением признака Y , а распределением вероятностей на множестве Y и осуществляется предсказание с вероятностью $p(y_i|x_i, \theta)$, которое нужно уточнить до эталонного значения распределения $p_t(y_i|x_i)$. Фактически речь идет о том, что если множество Y непрерывно, то задача приближения, предсказанного заранее распределения, к эталонному виду означает задачу сближения функций плотности вероятностей. Представленная постановка задачи может быть рассмотрена по-разному, в зависимости от того, что мы вкладываем в понятие “расстояния” между функциями. Чаще всего используется так называемое расхождение Кульбака-Лейблера [36], описывающее относительную энтропию, т. е. некую несимметричную метрику сходства между двумя вероятностями. Описанную величину можно рассмотреть, как в дискретном виде (2), так и в непрерывном виде (3), в зависимости от сформулированной задачи:

$$D(P||Q) = \mathbb{E}(x \sim p) \lg \frac{P(x)}{Q(x)} = \sum_{x \in X} P(x) \lg \frac{P(x)}{Q(x)}, \quad (2)$$

где $P(x)$, $Q(x)$ – функции вероятностей.

$$D(p||q) = \mathbb{E}(x \sim p) \lg \frac{p(x)}{q(x)} = \int_{x \in X} p(x) \lg \frac{p(x)}{q(x)}, \quad (3)$$

где $p(x)$, $q(x)$ – функции плотности вероятностей. Пользуясь свойствами логарифмов, справедливо перейти к виду:

$$D(P||Q) = \sum_{x \in X} P(x) \lg P(x) - \sum_{x \in X} P(x) \lg Q(x), \quad (4)$$

В данном случае первое слагаемое является дифференциальной энтропией случайной величины в непрерывном случае, а второе, упрощенно описанной ранее перекрестной энтропией. Так как классификатор основывается на обучении нейросетевой модели, мы имеем некоторое количество обучающих пар (x_i, y_i) , при этом точно известно, что $y_i \in Y$, значит его можно представить, как вырожденное

распределение вероятностей на множестве Y , т. е. имеющее только одно возможное значение y_i с вероятностью равной единице. Тогда для вычисления перекрестной энтропии между эталонным и предсказанным распределением удобнее всего будет использовать дельта-функцию Дирака:

$$c(\delta((y - y_t), p(y_i|x_i, \theta))) = - \int_{-\infty}^{\infty} \delta((y - y_t) \lg p(y_i|x_i, \theta)) dy = -\lg p(y_i|x_i, \theta), \quad (5)$$

где $\delta(y - y_t)$ – дельта-функция Дирака, выражающая эталонное распределение, $p(y_i|x_i, \theta)$ – нормальное распределение. Фактически, полученное значение выражения (5) можно использовать для минимизации перекрестной энтропии между эталонным и предсказанным распределением, т. к. оба аргумента в формуле (5) являются не числами, а функциями от y и подынтегральное выражение не равно нулю лишь в одной точке y_t , то минимизация $-\lg p(y_i|x_i, \theta)$ означает максимизацию $p(y_i|x_i, \theta)$. Это значит, что модель обучается с помощью перекрестной энтропии, которая путем преобразований по формуле (5) приводит к минимизации значений среднеквадратического отклонения, если в основе модели считаем за нормальное распределение.

Из раздела *Images* в *TensorBoard* в процессе обучения можно отследить то, какими были модели во время процесса обучения. Процесс обучения модели представлен на рисунке 2.

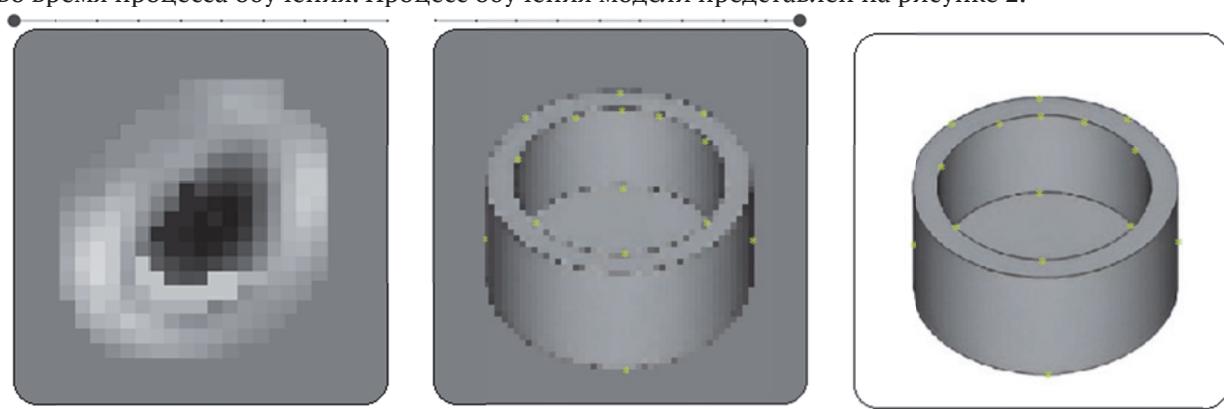


Рис. 2. Процесс обучения в *TensorFlow*

В ходе машинного обучения была достигнута высокая точность распознавания и классификации деталей до 99,1%. На рисунке 3 можно видеть график изменения скалярной величины, характеризующей точность, описанную выше.

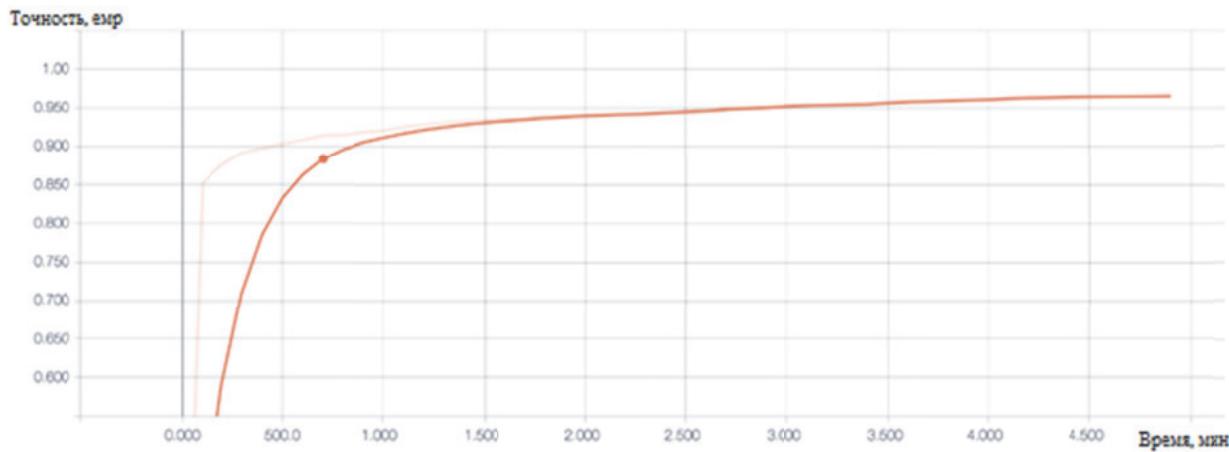


Рис. 3. Точность машинного обучения

РЕЗУЛЬТАТЫ. ПРОВЕРКА КЛАССИФИКАТОРА НА ВЫБРАННЫХ 3Д И ГЕНЕРАТИВНЫХ МОДЕЛЯХ

Сформированный с применением искусственного интеллекта классификатор позволяет распознать задаваемую на вход модель и отнести ее в нужную категорию. В таблице 5 представлены значения точности и полноты распознавания объектов после работы алгоритма (детали пронумерованы условно).

Таблица 5. Характеристики объектов алгоритма машинного обучения

Значение	1	2	3	4	5
Точность	0,87	0,94	0,95	0,99	0,98
Полнота	0,85	0,87	0,86	0,88	0,88

Из представленных характеристик (см. табл. 5) видно, что точность классификации достигает 99%, при этом при выборке объектов отсеивается не более 15% входных данных. Нейронной сети удалось распознать все входные детали, сложность при определении возникла с некоторыми полыми деталями в связи со сложностью определения границ внутренней образующей.

Классификатор смог точно определить класс 99,1% предъявляемых деталей. В дальнейшем, опираясь на приведенные результаты, классификатор может быть использован при выборе математической модели для решения ряда задач, основываясь на геометрии деталей, в том числе задач нестационарного течения по поверхностям слоя пластиически деформируемого металла (аналог задачи Прандтля), свободного затекания в пазы или течения с наложением ограничений в одном или нескольких направлениях.

СПИСОК ЛИТЕРАТУРЫ

1. Ишилинский, А.Ю. Математическая теория пластичности/ А.Ю. Ишилинский, Д.Д. Ивлев. – М.: Физматлит, 2001. – 704 с.
2. Ковка и штамповка. Справочник. В 4-х томах [ред. совет: Е.И. Семенов (пред.) и др.] – М.: Машиностроение, 1987. – Т.3. – Холодная объемная штамповка [под ред. Г.А. Навроцкого]. – 1987. – 384 с.
3. Евстратов, В.А. Основы технологии выдавливания и конструирования штампов /В.А. Евстратов. – Харьков: Выща школа, 1987. – 384 с.
4. Артес, А.Э. Групповое производство деталей холодной объемной штамповкой / А.Э. Артес. – М.: Машиностроение, 1991. – 192 с.
5. Краев, Л.Ф. Построение классификатора кованых и штампованных поковок / Л.Ф. Краев // Кузнечно-штамповочное производство. – 1975. – № 2. – С. 20-22.
6. Ланской, Е.Н. Автоматизация проектирования групповых процессов холодной и полугорячей объемной штамповки при многономерном производстве деталей/ Е.Н. Ланской, Е.Н. Сосенушкин. – М., 1989. – 84 с. (Машиностроительное производство. Сер. Технология и оборудование кузнечно-штамповочного производства: Обзорн. информ. / ВНИИТЭМР. Вып. 6).
7. Сосенушкин, Е.Н. Прогрессивные процессы объемной штамповки / Е.Н. Сосенушкин. – М.: Машиностроение, 2011. – 480 с.
8. Аткинсон, Р. Введение в математическую теорию обучения / Р. Аткинсон, Г. Бауэр, Э. Кротерс. – М.: Мир, 1969. – 486 с.
9. Исаченкова, Н.Е. Классификация деталей в решении проблемы оценки уровня технологических процессов обработки металлов давлением / Н.Е. Исаченкова// Кузнечно-штамповочное производство. – 1981. – № 4. – С. 32-35.
10. Сосенушкин, Е.Н. Математическая модель адгезионного износа штампов объемной штамповки/ Е.Н. Сосенушкин, А.В. Хроменков, Ю.А. Мельник // Трение и износ. – 2014. – Т. 35. – № 6. – С. 752-758.
11. Сосенушкин, Е.Н. Система автоматизированного выбора материалов для штампов холодной и полугорячей объемной штамповки/ Е.Н. Сосенушкин// В кн.: Актуални проблеми на пластичната обработка на металите. – Варна, 1990. – С. 379 – 385.
12. Евстифеев, В.В. Классификация технологических процессов холодной объемной штамповки. Вопросы групповой технологии/ В.В. Евстифеев, А.Э. Артес. – М.: Машиностроение. 1987. – 80 с.
13. Загоруйко, Н.Г. Методы распознавания и их применение/ Н.Г. Загоруйко. – М.: Советское радио, 1972. – 206 с.
14. Айзерман, М.А. Метод потенциальных функций в теории обучения машин/ Э.М. Браверман, Л.И. Розеноэр. – М.: Наука, 1970. – 383 с.
15. Ильюшин, А.А. Механика сплошной среды. Учебник/ А.А. Ильюшин. – М.: Изд-во МГУ, 1978. – 287 с.
16. Хант, Э. Искусственный интеллект / Э. Хант. – М.: Мир, 1978. – 558 с.
17. Дорофеюк, А.А. Алгоритмы автоматической классификации / А.А. Дорофеюк // В кн.: Проблемы расширения возможностей автоматов. – М.: Институт проблем управления АН СССР, 1971. – Вып. 1. – С. 5-41.
18. Ларичев, О.И. Выявление экспертных знаний / О.И. Ларичев, А.И. Мечитов, Е.М. Мошкович, Е.М. Фуремс. – М.: Наука, 1989. – 128 с.
19. Родзина, О.Н. Проблемно-ориентированные алгоритмы мягких вычислений: монография / О.Н. Родзина. – Чебоксары: ИД «Среда», 2020. – 96 с.
20. Кугаевских, А.В. Классические методы машинного обучения / А.В. Кугаевских, Д.И. Муромцев, О.В. Кирсанова. – СПб: Университет ИТМО, 2022. – 53 с.

21. Joseph M. Hilbe. Practical Guide to Logistic Regression / M. Hilbe Joseph // New York, Chapman and Hall/CRC, 2015. P. 174.
22. Куприянов, М.С. Применение теории графов для разработки прямого метода построения деревьев решений / М.С. Куприянов, Ю.А. Шичкина // Братский государственный университет. – 2012. – №4. – С. 62-65
23. Чистяков, С.П. Случайные леса: Обзор/ С.П. Чистяков// Труды Карельского научного центра РАН. – 2013. – № 1. – С. 117-136.
24. Гафаров, Ф.М. Искусственные нейронные сети и приложения: учеб. пособие / Ф.М. Гафаров, А.Ф. Галимянов. – Казань: Изд-во Казан. ун-та, 2018. – 121 с.
25. Фролов, И.И. Построение классификатора на основе машины опорных векторов для распознавания символов / И.И. Фролов, Р.Х. Садыхов // Доклады Белорусского государственного университета информатики и радиоэлектроники. – 2008. – № 1 (31). – С.103-108.
26. Фостер, Дэвид. Генеративное глубокое обучение. Творческий потенциал нейронных сетей / Дэвид Фостер. – СПб.: Питер, 2020. – 336 с.: ил. (Серия «Бестселлеры O'Reilly»).
27. Дегтярев, Ю.И. Методы оптимизации: Учеб. пособие для вузов / Ю. И. Дегтярев. М.: Сов. радио, 1980. – 272 с.
28. Ту, Дж. Принципы распознавания образов/ Дж. Ту, Р. Гонсалес. – М.: Мир, 1978. – 411 с.
29. Лейси, Никола. Python, например. – СПб.: Питер, 2021. – 208 с.: ил. – (Серия «Библиотека программиста»).
30. Сосенушкин, Е.Н. Применение методов искусственного интеллекта для компьютерного моделирования фрактальных поверхностей / Е.Н. Сосенушкин, Е.А. Яновская, А.С. Желнов // Известия Самарского научного центра РАН. – 2024. – № 1. – С. 109–115.
31. Сосенушкин, Е.Н. Компьютерное моделирование фрактальных поверхностей, построенных с использованием методов искусственного интеллекта для прогнозирования износа/ Е.Н. Сосенушкин, Е.А. Яновская, А.С. Желнов // Известия Самарского научного центра РАН. – 2024. – № 4. – С. 143–149
32. Вакуленко, С.А. Практический курс по нейронным сетям/ С.А. Вакуленко, А.А. Жихарева. – СПб: Университет ИТМО, 2018. – 71 с.
33. Михайлова, Г.А. Статистическое моделирование. Методы Монте-Карло: учебное пособие для вузов / Г.А. Михайлова, А.В. Войтишек. – М.: Юрайт, 2024. – 323 с.
34. Гольдберг, Й. Нейросетевые методы в обработке естественного языка / пер. с англ. А. А. Слинкина. – М.: ДМК Пресс, 2019. – 282 с.
35. Мухамедиев, Р.И. Введение в машинное обучение: Учебник/ Р.И. Мухамедиев, Е.Н. Амирзалиев. – Алматы, 2022. – 252 с.
36. Кульбак, С. Теория информации и статистика / С. Кульбак. – М.: Наука, 1967. – 408 с.

CLASSIFICATION OF PARTS BY ARTIFICIAL INTELLIGENCE METHODS WHEN CHOOSING A MATHEMATICAL MODEL FOR SOLVING PLASTIC FLOW PROBLEMS

© 2025 E. N. Sosenushkin, E. A. Yanovskaya, A. S. Zhelnov

Moscow State Technological University “STANKIN”, Moscow, Russia

To select an adequate mathematical model for a specific problem of continuous medium mechanics (CMM), it is often necessary to resort to classifiers that allow dividing blanks or parts by certain characteristics. Usually, design and/or technological characteristics of parts are considered. Functional, parametric, design features of these parts, including geometric shape, can be selected as characteristics. The paper describes the possibility of constructing a classifier of parts using artificial intelligence methods for further use of the classifier when selecting a mathematical model for solving a number of CMM problems, including the problem of free flow in a thin layer or flow with the imposition of restrictions in one or more directions. For computer modeling, the method of machine learning of neural networks is used to select parts by geometric characteristics and combine these objects into the required category laid down in the program algorithm by the operator. Based on such “artificial selection”, a general classification procedure is created. At the end of the computer modeling, the classifier developed using artificial intelligence was verified using ready-made 3D models and models created by a generative neural network algorithm. The proposed work examines the stages of creating a classifier, its main parts and computer modeling methods, including using artificial intelligence methods.

Keywords: artificial intelligence; automatic classification; machine learning; mathematical modeling.

DOI: 10.37313/1990-5378-2025-27-2-170-179

EDN: IRHRGU

REFERENCES

1. Ishlinstkij, A.Yu. Matematicheskaya teoriya plastichnosti/ A.Yu. Ishlinstkij, D.D. Ivlev. – М.: Fizmatlit, 2001. – 704 s.
2. Kovka i shtampovka. Spravochnik. V 4-h tomah [red. sovet: E.I. Semenov (pred.) i dr.] – М.: Mashinostroenie, 1987. – T.3. – Holodnaya ob’emnaya shtampovka [pod red. G.A. Navrockogo]. – 1987. – 384 s.
3. Evstratov, V.A. Osnovy tekhnologii vydavlivaniya i konstruirovaniya shtampov /V.A. Evstratov. – Xar’kov: Vyshcha shkola, 1987. – 384 s.

4. *Artes, A.E.* Gruppovoe proizvodstvo detalej holodnoj ob»emnoj shtampovkoj / A.E. Artes. – M.: Mashinostroenie, 1991. – 192 s.
5. *Kraev, L.F.* Postroenie klassifikatora kovanyh i shtampovannyh pokovok / L.F. Kraev // Kuznechno-shtampovochnoe proizvodstvo. – 1975. – № 2. – S. 20-22.
6. *Lanskoy, E.H.* Avtomatizaciya proektirovaniya gruppovyh processov holodnoj i polugoryachej ob»emnoj shtampovki pri mnogonomenklaturalnom proizvodstve detalej/ E.H. Lanskoj, E.H. Sosenushkin. – M., 1989. – 84 s. (Mashinostroitel'noe proizvodstvo. Ser. Tekhnologiya i oborudovanie kuznechno-shtampovochnogo proizvodstva: Obzorn. inform. / VNIITEMR. Vyp. 6).
7. *Sosenushkin, E.N.* Progressivnye processy ob»emnoj shtampovki / E.N. Sosenushkin. – M.: Mashinostroenie, 2011. – 480 s.
8. *Atkinson, R.* Vvedenie v matematicheskuyu teoriyu obucheniya / R. Atkinson, G. Bauer, E. Kroters. – M.: Mir, 1969. – 486 s.
9. *Isachenkova, N.E.* Klassifikaciya detalej v reshenii problemy ocenki urovnya tekhnologicheskikh processov obrabotki metallov davleniem / N.E. Isachenkova// Kuznechno-shtampovochnoe proizvodstvo. – 1981. – № 4. – S. 32-35.
10. *Sosenushkin, E.N.* Matematicheskaya model' adgezionnogo iznosa shtampov ob»emnoj shtampovki/ E.N. Sosenushkin, A.V. Hromenkov, Yu.A. Mel'nik // Trenie i iznos. – 2014. – T. 35. – № 6. – S. 752-758.
11. *Sosenushkin, E.N.* Sistema avtomatizirovannogo vybora materialov dlya shtampov holodnoj i polugoryachej ob»emnoj shtampovki/ E.N. Sosenushkin// V kn.: Aktualni problemi na plastichnata obrabotka na metalite. – Varna, 1990. – S. 379 – 385.
12. *Evtseev, B.B.* Klassifikaciya tekhnologicheskikh processov holodnoj ob»emnoj shtampovki. Voprosy gruppovoj tekhnologii/ B.B. Evtseev, A.E. Artes. – M.: Mashinostroenie. 1987. – 80 s.
13. *Zagorukho, H.G.* Metody raspoznavaniya i ih primenenie/ H.G. Zagorukho. – M.: Sovetskoe radio, 1972. – 206 s.
14. *Ajzman, M.A.* Metod potencial'nyh funkciy v teorii obucheniya mashin/ E.M. Braverman, L.I. Rozonoer. – M.: Nauka, 1970. – 383 s.
15. *Il'yushin, A.A.* Mekhanika sploshnoj sredy. Uchebnik/ A.A. Il'yushin. – M.: Izd-vo MGU, 1978. – 287 s.
16. *Hant, E.* Iskusstvennyj intellekt / E. Hant. – M.: Mir, 1978. – 558 s.
17. *Dorofeyuk, A.A.* Algoritmy avtomaticheskoy klassifikacii / A.A. Dorofeyuk // V kn.: Problemy rasshireniya vozmozhnostej avtomatov. – M.: Institut problem upravleniya AN SSSR, 1971. – Vyp. 1. – S. 5-41.
18. *Larichev, O.I.* Vyyavlenie ekspertnyh znanij / O.I. Larichev, A.I. Mechetov, E.M. Moshkovich, E.M. Furems. – M.: Nauka, 1989. – 128 s.
19. *Rodzina, O.N.* Problemno-orientirovannye algoritmy myagkikh vychislenij: monografiya / O. N. Rodzina. – Cheboksary: ID «Sreda», 2020. – 96 s.
20. *Kugaevskih, A.V.* Klassicheskie metody mashinnogo obucheniya / A.V. Kugaevskih, D.I. Muromcev, O.V. Kirsanova. – SPb: Universitet ITMO, 2022. – 53 s.
21. *Joseph M. Hilbe.* Practical Guide to Logistic Regression / M. Hilbe Joseph // New York, Chapman and Hall/CRC, 2015. P. 174.
22. *Kupriyanov, M.S.* Primenenie teorii grafov dlya razrabotki pryamogo metoda postroeniya derev'ev reshenij / M.S. Kupriyanov, Yu.A. Shchikina // Bratskij gosudarstvennyj universitet. – 2012. – №4. – S. 62-65
23. *Chistyakov, S.P.* Sluchajnye lesa: Obzor/ S.P. Chistyakov// Trudy Karel'skogo nauchnogo centra RAN. – 2013. – № 1. – S. 117-136.
24. *Gafarov, F.M.* Iskusstvennye nejronnye seti i prilozheniya: ucheb. posobie / F.M. Gafarov, A.F. Galimyanov. – Kazan': Izd-vo Kazan. un-ta, 2018. – 121 s.
25. *Frolov, I.I.* Postroenie klassifikatora na osnove mashiny opornyh vektorov dlya raspoznavaniya simvolov / I.I. Frolov, R.H. Sadygov // Doklady Belorusskogo gosudarstvennogo universiteta informatiki i radioelektroniki. – 2008. – № 1 (31). – S.103-108.
26. *Foster, Devid.* Generativnoe glubokoe obuchenie. Tvorcheskij potencial nejronnyh setej / Devid Foster. – SPb.: Piter, 2020. – 336 s.: il. (Seriya «Bestsellery O'Reilly»).
27. *Degtyarev, Yu.I.* Metody optimizacii: Ucheb. posobie dlya vuzov / Yu. I. Degtyarev. M.: Sov. radio, 1980. – 272 s.
28. *Tu, Dzh.* Principy raspoznavaniya obrazov/ Dzh. Tu, R. Gonsales. – M.: Mir, 1978. – 411 s.
29. *Lejsi, Nikola.* Python, naprimer. – SPb.: Piter, 2021. – 208 s.: il. – (Seriya «Biblioteka programmista»).
30. *Sosenushkin, E.N.* Primenenie metodov iskusstvennogo intellekta dlya komp'yuternogo modelirovaniya fraktal'nyh poverhnostej / E.N. Sosenushkin, E.A. Yanovskaya, A.S. Zhelnov // Izvestiya Samarskogo nauchnogo centra RAN. – 2024. – № 1. – S. 109–115.
31. *Sosenushkin, E.N.* Komp'yuternoe modelirovanie fraktal'nyh poverhnostej, postroennyh s ispol'zovaniem metodov iskusstvennogo intellekta dlya prognozirovaniya iznosa/ E.N. Sosenushkin, E.A. Yanovskaya, A.S. Zhelnov // Izvestiya Samarskogo nauchnogo centra RAN. – 2024. – № 4. – S. 143–149
32. *Vakulenko, S.A.* Prakticheskij kurs po nejronnym setyam/ S.A. Vakulenko, A.A. Zhihareva. – SPb: Universitet ITMO, 2018. – 71 s.
33. *Mihajlov, G.A.* Statisticheskoe modelirovanie. Metody Monte-Karlo: uchebnoe posobie dlya vuzov / G. A. Mihajlov, A. V. Vojtishek. – M.: Yurajt, 2024. – 323 s.
34. *Gol'dberg, J.* Nejrosetevye metody v obrabotke estestvennogo yazyka / per. s ang. A. A. Slinkina. – M.: DMK Press, 2019. – 282 s.
35. *Muhamediev, R.I.* Vvedenie v mashinnoe obuchenie: Uchebnik/ R.I. Muhamediev, E.N. Amirgaliev. – Almaty, 2022. – 252 s.
36. *Kul'bak, S.* Teoriya informacii i statistika / S. Kul'bak. – M.: Nauka, 1967. – 408 s.

Evgeny Sosenushkin, Doctor of Technical Sciences, Professor of the Department of Plastic Deformation Systems.

E-mail: sen@stankin.ru

Elena Yanovskaya, Candidate of Technical Sciences, Associate Professor of the Department of Applied Mathematics.

E-mail: elena_yanovskaya@bk.ru

Andrey Zhelnov, Lecturer of the Department of Applied Mathematics. E-mail: a.zhelnov@stankin.ru