

УДК 519.2

Научная статья

## **Модель оценки величины приложенного давления на основе анализа сигналов тактильного сенсора с применением методов машинного обучения**

***П. С. Козырь, Р. Н. Яковлев***

Федеральное государственное бюджетное учреждение науки "Санкт-Петербургский Федеральный исследовательский центр Российской академии наук" (СПб ФИЦ РАН), Санкт-Петербургский институт информатики и автоматизации Российской академии наук, 14 линия д. 39, г. Санкт-Петербург, 199178, Россия.

E-mail: polinatrump@mail.ru

В рамках настоящего исследования был проведен анализ существующих работ, посвященных интерпретации показаний тактильных сенсорных устройств, по результатам которого была предложена модель машинного обучения, позволяющая осуществлять оценку величины приложенного давления к поверхности тактильного сенсора давления емкостного типа. В качестве опорных моделей обработки и интерпретации сигналов данного устройства в работе рассматривались несколько методов машинного обучения: линейная регрессия, полиномиальная регрессия, регрессия дерева решений, частичная регрессия наименьших квадратов и полносвязная нейронная сеть прямого распространения. Обучение опорных моделей и апробация конечного решения проводилась на авторском наборе данных, включающем в себя более 3000 экземпляров данных. Согласно полученным результатам, наилучшее качество определения величины приложенного давления продемонстрировано решением на основе полносвязной нейронной сети прямого распространения. Коэффициент детерминации и средний модуль отклонения для данного решения на тестовой выборке составили 0,93 и 13,14 кПа соответственно.

*Ключевые слова: емкостной сенсор давления, оценка величины давления, регрессионные модели, kNN, полносвязная нейронная сеть прямого распространения.*

DOI: 10.26117/2079-6641-2021-37-4-119-130

Поступила в редакцию: 16.11.2021

В окончательном варианте: 14.12.2021

**Для цитирования.** Козырь П. С., Яковлев Р. Н. Модель оценки величины приложенного давления на основе анализа сигналов тактильного сенсора с применением методов машинного обучения // *Вестник КРАУНЦ. Физ.-мат. науки.* 2021. Т.37. № 4. С. 119-130. DOI: 10.26117/2079-6641-2021-37-4-119-130

*Контент публикуется на условиях лицензии Creative Commons Attribution 4.0 International* (<https://creativecommons.org/licenses/by/4.0/deed.ru>)

© Козырь П. С., Яковлев Р. Н., 2021

**Финансирование.** Исследование выполнялось без финансирования

## 1. Введение

Тактильные сенсоры играют важнейшую роль в конструировании робототехнических систем (РС). Благодаря им робототехническое средство может получать дополнительную информацию в процессе взаимодействия с окружающей средой, что позволяет повысить качество решения поставленных перед ним задач. Датчики давления наделяют робототехнические средства способностью реагировать на тактильные контакты с окружающими объектами, возникающими в рабочей зоне. В частности, такие сенсоры служат элементом обратной связи для системы захвата объектов [1]-[3]. Кроме того, они нередко находят свое применение в системах медицинского назначения для контроля позы и походки человека [4]. Анализ и интерпретация данных тактильных датчиков зачастую осложняется как зависимостью показателей таких сенсоров от типа материала объекта, оказывающего давление на сенсор, так и конструктивными особенностями каждого отдельно взятого устройства. Одной из распространенных практик, направленных на решение указанной проблемы, является разработка специализированных моделей интерпретации показаний устройства на основе методов машинного обучения. В данной работе представлена модель машинного обучения, обеспечивающая оценку величины давления, прикладываемого к поверхности тактильного сенсора [5]-[6], на основе выходных сигналов данного устройства.

## 2. Современное состояние исследований

В качестве инструмента для обработки и анализа данных, полученных от тактильных датчиков, широко используются методы машинного и глубокого обучения [7]-[13]. В частности, в работе [4] исследователи предложили решение, осуществляющее контроль походки человека на основе анализа данных, считанных с чувствительной к давлению стельки, с помощью метода  $k$ -ближайших соседей. Стелька состояла из многостенных углеродных нанотрубок и полидиметилсилоксана (PDMS). Авторы работы рассматривали задачу определения фазы походки человека как задачу многоклассовой классификации. В результате, точность распознавания трех фаз походки методом  $k$ -ближайших соседей составила 97%.

В работе [7] проводилось распознавание позы человека в положении сидя. Мониторинг положения тела осуществлялся на основе информации о распределении давления, полученной от тринадцати пьезорезистивных датчиков, установленных на сидении и спинке кресла. Распознавания пяти поз по данным датчиков давления осуществлялось с помощью таких методов машинного обучения, как дерево решений, метод опорных векторов, метод  $k$ -ближайших соседей и нейронная сеть прямого распространения. Метод  $k$ -ближайших соседей ( $k$ NN) был реализован в двух вариациях с различными схемами взвешивания соседей. По результатам проведенных экспериментов наилучшие результаты продемонстрировал метод  $k$ NN, использующий гауссову функцию для оценки весов, точность данного решения составила 98%.

Исследование, представленное в работе [8], также было направлено на мониторинг позы человека в положении сидя. С помощью тензодатчиков, расположенных в кресле, были получены данные о распределении давления, оказываемого человеком в различных позах. Для классификации шести

предварительно определенных поз авторами были апробированы такие методы машинного обучения, как метод опорных векторов (МОВ) с радиальной базисной функцией в качестве ядра (RBF kernel), МОВ с линейной ядерной функцией (linear kernel), линейный дискриминантный анализ, квадратичный дискриминантный анализ (quadratic discriminant analysis), наивный байесовский классификатор и случайный лес. Наилучшую точность (97%) среди исследованных классификаторов продемонстрировал МОВ с радиальной базисной функцией в качестве ядра.

В работе [9] авторами был предложен индуктивно-емкостной датчик для оценки величины прикладываемого давления. В качестве модели для обработки и анализа данных с датчика была выбрана модель сверточной нейронной сети. Диапазон приложенного давления в рамках проведенных экспериментов составлял от 0 до 10 кПа. В результате, величина среднеквадратичной ошибки определения давления сверточной нейронной сетью составила 0,12 кПа.

Авторы работы [10] на основе данных инерциального измерительного модуля, закрепляемого на поясище человека, и датчика давления в стельке обуви производили оценку состояния поясничного отдела пользователя. Задача оценки состояния поясницы рассматривалась как задача множественной регрессии. Для решения поставленной задачи авторами было апробировано несколько алгоритмов машинного обучения, таких как обобщенная линейная модель, метод опорных векторов, базовые нейросетевые модели и др. В конечном счете, наиболее многообещающие результаты были достигнуты при использовании дерева решений с градиентным усилением (Gradient Boosted Decision Tree). Коэффициент детерминации данного метода достиг более 0,85 для тестовой выборки.

В рамках исследования [11] был представлен метод мониторинга сердцебиения водителя автомобиля на основе данных сигналов датчиков давления, прикрепленных к спинке сидения. В качестве метода распознавания позы авторами был выбран EML алгоритм (extreme learning machines). В процессе исследований авторами была обнаружена корреляция между данными сигналов сердцебиения и сигналами датчиков давления. Таким образом, на основе данных о распределении давления тела человека на сидение в той или иной позе извлекалась информация о его сердцебиении. EML алгоритм в задаче выявления позы водителя продемонстрировал точность порядка 95%.

В работе [12] рассматривалась проблема распознавания текстуры поверхности объекта на основе данных датчиков давления Maya pyramid pressure sensors. В исследовании она была сформулирована в виде задачи классификации шести различных текстур. В качестве алгоритма распознавания текстур авторы использовали нейронные сети долгой-краткосрочной памяти (long-short time memory network), точность распознавания которых в рамках проведенных экспериментов составила 98%.

Авторы работы [13] также провели исследование в отношении проблемы распознавания текстур объекта с помощью датчиков давления. В качестве входных данных для выбранного метода глубокого обучения (сверточная нейросетевая модель) использовались значения сигналов, поступающих с пьезорезистивных датчиков давления, созданных с использованием массива трехмерных металлических кольцевых трещин на полимерных микроструктурах. В рамках проведенных экспериментов осуществлялось распознавание десяти материалов разной текстуры. Согласно полученным результатам, при удержании давления на датчике в течение 4

с максимальной точностью классификации этим методом составила 94%, в течение 1 с – 76,2%.

По результатам проведенного анализа методов, направленных на обработку и анализ показателей тактильных датчиков, можно сделать вывод, что при разработке соответствующих решений используется широкий инструментарий методов машинного обучения, при этом предпочтение отдается преимущественно классическим методам, дополненным отдельными компонентами, обусловленными спецификой решаемой задачи. Таким образом, в рамках настоящего исследования при разработке модели оценки величины приложенного давления, исходя показателей тактильного сенсора [5], в качестве опорных моделей также планируется апробировать ряд классических методов машинного обучения.

### 3. Предлагаемый метод

В рамках настоящей работы рассматривается задача интерпретации показателей тактильного сенсора емкостного типа [5]. Данный сенсор имеет высокую чувствительность, устойчив к температурным колебаниям и обладает широким динамическим диапазоном [1]-[2]. Диапазон значений величины давления, который охватывает данный сенсор, составляет от 0 до 245 кПа. Пример графика зависимости давления, приложенного к сенсору, от выходных значений сигнала после прохождения аналогово-цифрового преобразователя (АЦП) представлен на рис. 1.

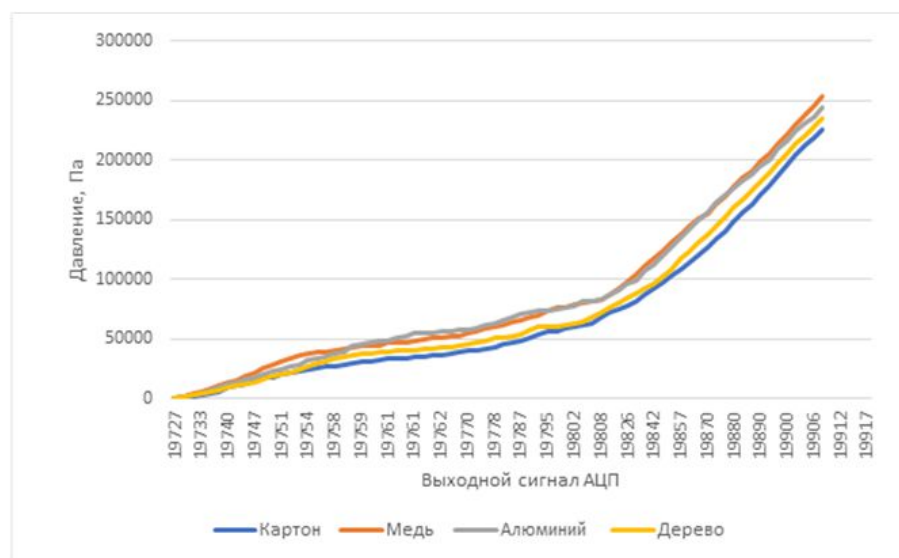


Рис. 1. График зависимости величины приложенного давления от выходных значений сигнала датчика [5] после прохождения АЦП для различных материалов

Как можно заметить из представленного выше графика, зависимости между показателями датчика и величинами приложенного давления существенно отличаются для различных материалов. При этом для некоторых из них наблюдается более высокая корреляция между полученными зависимостями величины давления от показателей датчика. В рамках настоящего исследования была принята гипотеза, что тип материала (диэлектрик или проводник) существенным образом влияет на конечный вид зависимости величины давления от регистрируемых показателей

сенсора. Исходя из того, что пространство значений оцениваемой величины условно непрерывно и соответствует диапазону от 0 до 245 кПа в работе было принято решение рассматривать задачу оценки величины давления как задачу регрессии. С учетом представленных выше предпосылок, была предложена следующая архитектура модели оценки величины приложенного к датчику давления (рис. 2).

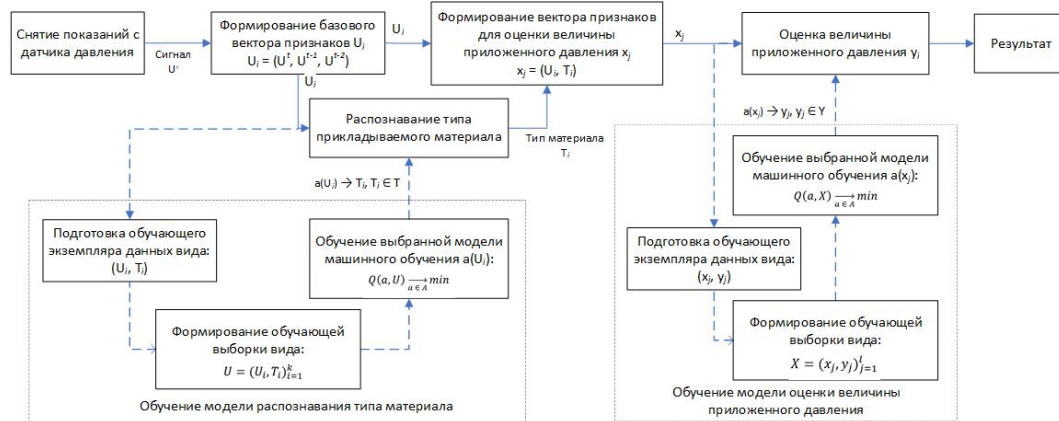


Рис. 2. Архитектура модели оценки величины приложенного давления

Как можно заметить, предложенная архитектура включает в себя два ключевых блока анализа данных, первый из которых направлен на распознавание типа материала, с которым осуществляется взаимодействие, а второй посвящен непосредственной оценке величины приложенного к датчику давления. В рамках предложенной модели задача распознавания типа материала рассматривается как задача бинарной классификации, а обучающая выборка для соответствующей группы опорных моделей имеет следующий вид:

$$U = (U_i, T_i)_{i=1}^k,$$

где  $U_i$  – вектор признаков вида  $(U^t, U^{t-1}, U^{t-2})$ , элементы которого представляют собой значения сигнала с сенсора давления в некоторые моменты времени  $t, t-1$  и  $t-2$ , соответственно, а  $T_i$  – истинное значение типа материала для вектора признаков  $U_i$ . Таким образом, для решения задачи распознавания типа материала необходимо найти такой алгоритм  $a \in A$ , который бы минимизировал следующий функционал ошибки:

$$Q(a, U) \xrightarrow{a \in A} \min.$$

В случае блока, реализующего оценку величины приложенного к датчику давления, вектор признаков  $x_j$ , принимаемый на вход опорными моделями, представленными регрессионными моделями машинного обучения, определен следующим образом:

$$x_j = (U_i, T_i).$$

Таким образом, в рамках предложенной модели на первом этапе на основе показателей датчика осуществляется формирование базового вектора признаков вида:  $U_i = (U^t, U^{t-1}, U^{t-2})$ , который передается на вход опорной модели распознавания типа материала. Соответствующая модель возвращает спрогнозированный тип материала для объекта, взаимодействующего с сенсором. На следующем шаге

формируется результирующий вектор признаков  $x_j = (U_i, T_i)$ , подающийся на вход регрессионной модели оценки величины приложенного давления, которая непосредственно возвращает спрогнозированное значение величины приложенного давления  $u_j$ .

Особенностью предложенной модели оценки величины приложенного давления является использование данных о типе материала объекта помимо признаков, соответствующих амплитудным значениям сигнала датчика в различные моменты времени. Добавление признака, характеризующего тип приложенного материала, в вектор входных данных для опорных регрессионных моделей оценки позволит учесть специфику зависимости регистрируемых показателей сенсора от типа воздействующего материала и, как следствие, повысить точность определения величины приложенного давления.

Далее перейдем к оценке разработанной модели машинного обучения, обеспечивающей оценку величины давления, прикладываемого к поверхности тактильного сенсора [5]-[6], на основе выходных сигналов устройства.

#### 4. Эксперименты

В рамках настоящего исследования в качестве сенсора давления выступала единичная ячейка комбинированного датчика давления и приближения на основе первичного емкостного преобразователя [5]-[6]. Ячейка имеет размеры  $12 \times 12 \times 4,2$  мм и позволяет измерять приложенное давление в диапазоне от 0 до 245 кПа. Приложение давления к ячейке производилась с помощью испытательного стенда, представленного на рис. 3.




Рис. 3. Конструкция испытательного стенда. (1) – Поверхность, на которой расположен стенд, (2) – рама, (3) – шаговый двигатель, (4) винт передачи гайка-винт, (5) – каретка, (6) – закрепленный образец, (7) – емкостной датчик, (8) – измерительное устройство.

Приложение давления от каретки с закрепленным на ней образцом к емкостному датчику осуществлялось с помощью шагового двигателя и винта передачи гайка-винт. Обработка аналогового выходного сигнала, полученного с ячейки датчика, посредством АЦП высокой разрядности, позволила достичь высокой точности результатов проведения экспериментов. Контроль и измерение истинного значения давления выполнялись с помощью эталонного измерительного прибора [14].

В процессе формирования обучающего набора данных показатели сенсора давления подвергались процедуре нормирования. Все кривые значений сигналов, считанные с датчика при приложении различных величин давления, приводились к общему номинальному уровню напряжения в момент отсутствия давления объекта

на поверхность датчика. В качестве объектов, прикладываемых к емкостному датчику, использовались образцы различных материалов, таких как алюминий, дерево, картон, пластик, медь, стекло и ткань.

Важно отметить, что при приложении давления к датчику более 70 кПа, шаг изменения приложенного давления начинает заметно возрастать, в то время как шаг изменения амплитуды сигнала датчика остается неизменным. Таким образом, в обучающую выборку включается избыточное число экземпляров данных, соответствующих приложению давления к поверхности датчика менее 70 кПа, что приводит к значительной несбалансированности обучающего набора данных. Такая особенность обучающей выборки может негативно отразиться на результатах обучения моделей машинного обучения, а потому в процессе подготовки обучающего набора ряд экземпляров данных, соответствующих величине приложенного давления менее 70 кПа, были исключены из итоговой обучающей выборки.

Полученные в соответствии с данной стратегией обучающая и тестовая выборки состоят из 30 и 10 наборов данных, каждый из которых включает в себя около девяноста измерений амплитуды сигнала датчика для различных величин приложенного давления в диапазоне от 0 до 245 кПа. Для каждого из рассматриваемых материалов было собрано по шесть наборов данных указанного вида. Результирующий объем обучающей и тестовой выборки составил 2400 и 800 экземпляров данных, соответственно.

В соответствии с предложенной архитектурой модели оценки величины приложенного давления, для решения задачи распознавания типа материала был апробирован ряд алгоритмов машинного обучения, в частности, рассматривались: метод опорных векторов, алгоритм случайного леса, метод k-ближайших соседей и наивный байесовский классификатор [15]-[17]. В рамках проведенных экспериментов были получены оценки качества работы представленных выше методов машинного обучения на полной тестовой выборке из 800 экземпляров данных. Полученные результаты представлены в табл. 1.

Таблица 1

**Результирующие оценки качества решения задачи распознавания типа материала объекта взаимодействия при использовании выбранных методов машинного обучения**

Метод машинного обучения	Доля правильных ответов (Accuracy), %
Метод опорных векторов	69
Случайный лес	64
Метод k-ближайших соседей	71
Наивный байесовский классификатор	69

Согласно представленным результатам, лучшее качество распознавания типа материала продемонстрировал метод k-ближайших соседей, точность распознавания у которого составила 71%. На основании полученных данных было принято решение использовать метод kNN в качестве основы блока распознавания типа материала в составе архитектуры модели оценки величины приложенного давления.

В рамках дальнейших экспериментов в качестве опорных моделей для решения задачи оценки величины приложенного давления был последовательно апробирован ряд регрессионных моделей машинного обучения: линейная регрессия, полиномиальная регрессия, регрессия дерева решений, частичная регрессия

наименьших квадратов и полносвязная нейронная сеть прямого распространения (Keras) [18]-[21]. В табл. 2 представлена основная информация о значениях гиперпараметров, использованных в процессе обучения и тестирования указанных моделей.

Таблица 2

**Значения гиперпараметров, использованные в процессе обучения и тестирования моделей**

Метод машинного обучения	Параметры	
Линейная регрессия	Смещение	True
	Нормализация	False
Полиномиальная регрессия	Степень полинома	3
	Признак с нулевой полиномиальной степенью	True
Регрессия дерева решений	Максимальная глубина дерева	5
	Критерий оценки качества разделения в узле	MSE
	Число признаков, рассматриваемых в процессе разделения	log2 (Размер входного вектора признаков)
Частичная регрессия наименьших квадратов	Количество компонентов	3
	Алгоритм оценки первых сингулярных векторов матрицы кросс-ковариации	NIPALS
	Максимальное число итераций	500
Полносвязная нейронная сеть прямого распространения (Keras)	Количество скрытых слоев	1
	Функция активации слоя	Слой 1, 2 – ReLU;
		Слой 3 – сигмоида;
	Функция потерь	MSE
	Алгоритм оптимизации	Adam
	Количество эпох обучения	300
Размер пакета	10	

В качестве метрики оценки качества работы выбранных регрессионных моделей машинного обучения в рамках настоящего исследования был использован коэффициент детерминации  $R^2$ , определяемый уравнением:

$$R^2 = 1 - \frac{\sum_{i=1}^m |a_i - y_i|^2}{\sum_{i=1}^m |\bar{y} - y_i|^2}, \bar{y} = \frac{1}{m} \sum_{i=1}^m y_i,$$

где  $m$  – количество экземпляров данных в выборке,  $a_i$  – ответы, спрогнозированные моделью,  $y_i$  – истинные целевые значения прогнозируемой величины,  $\bar{y}$  – среднее арифметическое истинных значений величины.

Для определения среднего модуля отклонения спрогнозированной величины приложенного давления от истинного значения использовалось среднее



арифметическое отклонений всех результатов работы модели на тестовой выборке, определяемое уравнением вида:

$$\overline{\Delta y} = \frac{1}{m} \sum_{i=1}^m |a_i - y_i|.$$

Полученные результаты оценки точности предсказаний каждой из выбранных моделей машинного обучения представлены в табл. 3.

Таблица 3

**Результаты оценки точности определения величины приложенного давления к поверхности емкостного датчика давления и приближения**

Метод машинного обучения	Коэффициент детерминации	Средний модуль отклонения, кПа
Линейная регрессия	0,82	25,00
Полиномиальная регрессия	0,86	20,40
Регрессия дерева решений	0,89	17,30
Частичная регрессия наименьших квадратов	0,80	28,00
Полносвязная нейронная сеть прямого распространения (Keras)	0,93	13,14

Согласно полученным результатам, наилучшее качество определения величины приложенного давления продемонстрировала архитектура, где блок оценки величины приложенного давления был реализован с использованием полносвязной нейронной сети прямого распространения, коэффициент детерминации которой на тестовой выборке составил 0,93. Средний модуль отклонения спрогнозированного значения давления от истинной величины составил 13,14 кПа. Относительно высокие результаты также показала модель регрессора дерева решений, коэффициент детерминации и отклонение для которой составили, соответственно, 0,89 и 17,30 кПа. Наихудшие результаты среди рассмотренных методов машинного обучения показали методы линейной регрессии и частичной регрессии наименьших квадратов, что в значительной степени объясняется низкой обобщающей способностью данных моделей в отношении зависимостей нелинейного вида. На основании результатов проведенной экспериментальной оценки, полносвязная нейронная сеть прямого распространения была выбрана в качестве основы для блока интеллектуального анализа данных тактильного сенсора, направленного на определение величины приложенного давления.

Таким образом, в рамках настоящего исследования была предложена модель машинного обучения, обеспечивающая оценку величины давления, прикладываемого к поверхности тактильного сенсора, реализация которой была успешно апробирована в ходе проведения экспериментальной оценки на тестовом наборе данных.

## Заключение

По результатам апробации предложенной модели оценки величины приложенного давления к поверхности тактильного сенсора давления емкостного типа на тестовой

выборке из 800 экземпляров данных можно сделать вывод, что среди рассмотренных реализаций модели, наилучшие результаты достигаются при использовании метода kNN в качестве основы блока распознавания типа материала и полносвязной нейронной сети прямого распространения в качестве основы блока определения величины приложенного давления. Средний модуль отклонения спрогнозированного значения давления от истинной величины в данном случае составил 13,14 кПа, а коэффициент детерминации превысил 0,93. Важно отметить, что в случае наличия повышенных требований к быстродействию решения, интерпретация показаний сенсора давления может быть реализована с использованием менее ресурсоемкой модели регрессора дерева решений. Коэффициент детерминации и средний модуль отклонения для данной реализации составили соответственно 0,89 и 17,30 кПа.

Предложенная в данной работе модель может найти свое применение в различных робототехнических системах, в частности, в составе манипуляторов для контроля захвата и удержания объектов или в нижних конечностях антропоморфных робототехнических систем для повышения устойчивости походки.

**Конкурирующие интересы.** Авторы заявляют, что конфликтов интересов в отношении авторства и публикации нет.

**Авторский вклад и ответственность.** Все авторы участвовали в написании статьи и полностью несут ответственность за предоставление окончательной версии статьи в печать. Окончательная версия рукописи была одобрена всеми авторами.

## Список литературы/References

1. Chi, C., Sun, X., Xue, N., Li, T., Liu, C. Recent Progress in Technologies for Tactile Sensors // *Sensors*, 2018. vol. 18, no. 4, pp. 948.
2. Park, M., Bok, B.-G., Ahn, J.-H., Kim, M.-S. Recent Advances in Tactile Sensing Technology // *Micromachines*, 2018. vol. 9, no. 7, pp. 321.
3. Zou, L., Ge, C., Wang, Z., Cretu, E., Li, X. Novel Tactile Sensor Technology and Smart Tactile Sensing Systems: A Review // *Sensors*, 2017. vol. 17, no. 11, pp. 2653.
4. Heng, W., Pang, G., Xu, F., Huang, X., Pang, Z., Yang, G. Flexible Insole Sensors with Stably Connected Electrodes for Gait Phase Detection // *Sensors*, 2019. vol. 19, no. 23, pp. 5197.
5. Krestovnikov K., Cherskikh E., Zimuldinov E. Combined Capacitive Pressure and Proximity Sensor for Using in Robotic Systems // *Proceedings of 15th International Conference on Electromechanics and Robotics "Zavalishin's Readings"*, 2021, pp. 513-522.
6. Ерашов А.А., Крестовников К.Д., Быков А.Н. Разработка схмотехнического решения и конструкции емкостной матрицы датчиков давления для применения в робототехнике // *Робототехника и техническая кибернетика*, 2020. Т. 4. [Yerashov A. A., Krestovnikov K. D., Bykov A. N. Razrabotka skhemotekhnicheskogo resheniya i konstruktsii yemkostnoy matritsy datchikov davleniya dlya primeneniya v robototekhnike // *Robototekhnika i tekhnicheskaya kibernetika*, 2020. vol. 4 (In Russian)].
7. Fragkiadakis, E., Dalakleidi, K. V., Ni-kita, K. S. Design and Development of a Sitting Posture Recognition System // *41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 2019.
8. Roh, J., Park, H., Lee, K., Hyeong, J., Kim, S., Lee, B. Sitting Posture Monitoring System Based on a Low-Cost Load Cell Using Machine Learning // *Sensors*, 2018. vol. 18, no. 2, pp. 208.
9. Lee, G., Park, J., Byun, J., Yang, J. C., Kwon, S. Y., Kim, C., Jang, C., Sim J.Y., Yook J. G., Park, S. Parallel Signal Processing of a Wireless Pressure-Sensing Platform Combined with Machine-Learning-Based Cognition, Inspired by the Human Somatosensory System // *Advanced Materials*, 2019, pp. 1906269.
10. Matijevich E. S., Volgyesi P., Zelik K. E. A Promising Wearable Solution for the Practical and Accurate Monitoring of Low Back Loading in Manual Material Handling // *Sensors*, 2021. vol. 21, no. 2, pp. 340.
11. Jiang, Y., Deng, S., Sun, H., Qi, Y. Unconstrained monitoring method for heartbeat signals measurement using pressure sensors array // *Sensors*, 2019. vol. 19, no. 2, pp. 368.

12. Jung, M., Vishwanath, S. K., Kim, J., Ko, D.-K., Park, M.-J., Lim, S.-C., Jeon, S. Transparent and Flexible Mayan-Pyramid-based Pressure Sensor using Facile-Transferred Indium tin Oxide for Bimodal Sensor Applications // *Scientific Reports*, 2019. vol. 9, no. 1.
13. Yao, H., Yang, W., Cheng, W., Tan, Y. J., See, H. H., Li, S., Ali H.P.A., Lim B. Z.H., Liu Z., Tee, B. C. K. Near-hysteresis-free soft tactile electronic skins for wearables and reliable machine learning // *Proceedings of the National Academy of Sciences*, 2020. vol. 117, no. 41, pp. 202010989.
14. Весы DL-3102, Режим доступа <http://dl.demcom.ru/dl3102.html> (дата обращения – 20.03.2021). [ *Vesy DL-3102*, Rezhim dostupa <http://dl.demcom.ru/dl3102.html> (data obrashcheniya – 20.03.2021) (In Russian)].
15. Bolstad W.M., Curran J.M. *Introduction to Bayesian statistics*: John Wiley & Sons, 2016.
16. Smith C., Koning M. *Decision Trees and Random Forests: A Visual Introduction for Beginners*: Independently published, 2017.
17. Mirjalili S., Faris H., Aljarah I. *Evolutionary Machine Learning Techniques*: Springer, 2019.
18. Montgomery D., Peck E., Vining G. *Introduction to Linear Regression Analysis*, 2012.
19. Rokach L. *Data Mining with Decision Trees*, 2014.
20. Garson D. *Partial Least Squares: Regression and Structural Equation Models*, 2016.
21. Goodfellow I, Bengio Y, Courville A. *Deep Learning*, 2018.

## **A model for estimating the value of the applied pressure based on the analysis of tactile sensor signals using machine learning methods**

***P. S. Kozyr, R. N. Iakovlev***

St. Petersburg Federal Research Center of the Russian Academy of Sciences (SPC RAS), St. Petersburg Institute for Informatics and Automation of the Russian Academy of Sciences, 39, 14th Line, 199178, St. Petersburg, Russia.  
E-mail: polinatrump@mail.ru

Currently, in the field of developing sensing systems for robotic means, one of the urgent tasks is the problem of interpreting the data of tactile pressure and proximity sensors. As a rule, the solution to this problem is complicated both by the dependence of the indicators of tactile sensors on the type of object's material and by the design features of each individual device. In this study, an analysis of existing works devoted to the interpretation of the readings of tactile sensor devices was carried out. According to the analysis results a machine learning model was proposed that allows estimating the amount of pressure applied to the surface of a tactile pressure sensor of a capacitive type. The architecture of the proposed model includes two key blocks of data analysis, the first one is aimed at recognizing the type of interaction object's material and the second is devoted to the direct assessment of the magnitude of the pressure applied to the sensor. Several machine learning methods were considered as supporting models for processing and interpreting the signals of this device: linear regression, polynomial regression, decision tree regression, partial least squares regression and a fully connected feedforward neural network.

*Key words: capacitive pressure sensor, pressure value estimation.*

DOI: 10.26117/2079-6641-2021-37-4-119-130

Original article submitted: 16.11.2021

Revision submitted: 14.12.2021

**For citation.** Kozyr P. S., Iakovlev R. N. A model for estimating the value of the applied pressure based on the analysis of tactile sensor signals using machine learning methods. *Vestnik KRAUNC. Fiz.-mat. nauki.* 2021, **37**: 4, 119-130. DOI: 10.26117/2079-6641-2021-37-4-119-130

**Competing interests.** The authors declare that there are no conflicts of interest regarding authorship and publication.

**Contribution and Responsibility.** All authors contributed to this article. Authors are solely responsible for providing the final version of the article in print. The final version of the manuscript was approved by all authors.

*The content is published under the terms of the Creative Commons Attribution 4.0 International License (<https://creativecommons.org/licenses/by/4.0/deed.ru>)*

© Kozyr P. S., Iakovlev R. N., 2021

---

**Funding.** The study was carried out without funding