

МИНИСТЕРСТВО ОБРАЗОВАНИЯ И НАУКИ РОССИЙСКОЙ ФЕДЕРАЦИИ  
федеральное государственное бюджетное образовательное учреждение  
высшего образования  
«Тольяттинский государственный университет»

Институт математики, физики и информационных технологий

(наименование института полностью)

Кафедра «Прикладная математика и информатика»

(наименование кафедры)

02.03.03 Математическое обеспечение и администрирование  
информационных систем

(код и наименование направления подготовки, специальности)

Технология программирование

(направленность (профиль)/специализация)

## БАКАЛАВРСКАЯ РАБОТА

на тему «Использование алгоритма kNN в задаче диагностики качества сварных соединений»

Студент

В.А. Костылев

(И.О. Фамилия)

(личная подпись)

Руководитель

В.С. Климов

(И.О. Фамилия)

(личная подпись)

Допустить к защите

Заведующий кафедрой к.т.н, доцент, А.В. Очеповский

(ученая степень, звание, И.О. Фамилия)

(личная подпись)

« \_\_\_\_\_ » \_\_\_\_\_ 20 \_\_\_\_\_ Г.

Тольятти 2018

## АННОТАЦИЯ

Тема бакалаврской работы: «Использование алгоритма kNN в задаче диагностики качества сварных соединений».

В данной бакалаврской работе исследуются способы применения алгоритмов машинного обучения в задаче диагностики контактной сварки.

В работе предложен способ диагностики качества сварки с использованием индуктивного алгоритма машинного обучения kNN. В работе описывается процедура подготовки обучающей выборки на основе экспериментальных данных процесса сварки, процедура построения и использования классификатора качества сварки. Исследуется точность работы классификатора.

При проведении исследований, представленных в бакалаврской работе, было опубликовано 4 статьи.

Структура бакалаврской работы представлена введением, тремя главами, заключением, списком литературы.

Во введении описывается актуальность проводимого исследования, дается краткая характеристика проделанной работы.

В первой главе проводится обзор способов диагностики качества сварки с использованием алгоритмов машинного обучения.

Во второй главе описывается математический аппарат алгоритма kNN. Описывается процедура подготовки экспериментальных данных для анализа, алгоритм построения классификатора качества сварки.

В третьей главе приведены примеры использования предложенных подходов и описано разработанное программное обеспечение.

В заключении представлены выводы по проделанной работе.

В работе использовано 7 таблиц, 14 рисунков, список литературы содержит 20 литературных источников. Общий объем выпускной квалификационной работы составляет 42 страниц.

## **ABSTRACT**

The topic of the bachelor's work is: "Using the kNN algorithm in the problem of diagnosing the quality of welded joints".

In this bachelor's work the methods of application of machine learning algorithms in the problem of diagnostics of contact welding are investigated.

A method for diagnosing welding quality using the inductive algorithm of machine learning kNN is proposed. The paper describes the procedure for preparing a training sample based on the experimental data of the welding process, the procedure for constructing and using the welding quality qualifier. The accuracy of the classifier is investigated.

During the research presented in the bachelor's work, 4 articles were published.

The structure of the bachelor's work is represented by an introduction, three chapters, a conclusion, a list of literature.

In the introduction, the urgency of the research is described, a brief description of the work done is given.

In the first chapter, methods are used to diagnose welding quality using machine learning algorithms.

The second chapter describes the mathematical apparatus of the kNN algorithm. The procedure for preparing experimental data for analysis, the algorithm for constructing a welding quality classifier is described.

The third chapter gives examples of the use of the proposed approaches and describes the developed software.

In conclusion conclusions on the work done are presented.

The work uses 7 tables, 14 figures, the list of literature contains 20 literature sources. The total volume of the final qualifying work is 42 pages.

## СОДЕРЖАНИЕ

ВВЕДЕНИЕ .....	5
1 АНАЛИЗ СОСТОЯНИЯ ВОПРОСА .....	7
2 РАЗРАБОТКА АЛГОРИТМА ДИАГНОСТИКИ КАЧЕСТВА СВАРКИ НА ОСНОВЕ АЛГОРИТМА KNN.....	10
2.1 Технология классификация данных с использованием алгоритма kNN.....	10
2.2 Анализ данных процесса контактной сварки .....	17
2.3 Алгоритм диагностики качества контактной сварки на основе алгоритма kNN.....	21
3 ПРАКТИЧЕСКАЯ РЕАЛИЗАЦИЯ ПРЕДЛОЖЕННЫХ РЕШЕНИЙ.....	24
3.1 Апробация алгоритма на данных контактной сварки .....	24
3.2 Исследование точности работы классификатора в зависимости от параметра k .....	28
3.2 Программная реализация алгоритма диагностики .....	32
ЗАКЛЮЧЕНИЕ .....	37
СПИСОК ИСПОЛЬЗУЕМОЙ ЛИТЕРАТУРЫ .....	39

## ВВЕДЕНИЕ

Контактная точечная сварка один из самых популярных способов получения неразъемных соединений в производственной среде.

Производительность контактной сварки обеспечивается высокой скоростью протекания процесса – одно сварное соединение выполняется за десятые доли секунды. При этом качество сварки нестабильно из внешних случайных неконтролируемых воздействий. Поэтому актуальным вопросом на сегодняшний день остается разработка таких же высокопроизводительных способов контроля качества.

Современные способы контроля качества сварки основаны на методах машинного обучения, которые позволяют автоматизировать процесс настройки модели диагностики под любую номенклатуру свариваемых заготовок (различные толщины, материалы, критерии качества).

Для решения задачи диагностики сварки применяются такие методы машинного обучения, как нейронные сети прямого распространения, LVQ сети, рекуррентные нейронные сети, байесовские сети доверия, деревья классификации и регрессии.

Однако в настоящее время не существует исследований по применению алгоритма kNN в задачах диагностики контактной сварки.

Вопросами использования алгоритма kNN при решении практических задач занимаются такие исследователи, как Wenqian Shang, Houkuan Huang, Haibin Zhu, Yongmin Lin, Zhihai Wang, Youli Qu, Michał Łukasik, Marcin Sydow, Sampath Deegalla, Henrik Boström, Neamat El Gayar, Friedhelm Schwenker, Günther Palm, Maria Terzi, Matthew Rowe, Maria-Angela Ferrario, Debo Cheng и др [2-18].

В работе предложен способ диагностики качества сварки с использованием индуктивного алгоритма машинного обучения kNN. В работе описывается процедура подготовки обучающей выборки на основе

экспериментальных данных процесса сварки, процедура построения и использования классификатора качества сварки. Исследуется точность работы классификатора.

В исследовании проверяется гипотеза о том, возможности построения классификатора качества сварных соединений на основе алгоритма kNN.

Целью работы является автоматизация процесса диагностики сварки за счет разработки алгоритма построения классификатора качества сварных соединений, основанного на алгоритме машинного обучения kNN.

В ходе выполнения исследований была разработана программа, позволяющая по данным экспериментальных сварок производить классификацию качества сварных соединений.

Предложенные подходы были протестированы на экспериментальных данных контактной сварки. Полученный в ходе исследований классификатор качества позволяет по измеряемым в процессе сварки параметрам оценивать класс качества сварных соединений с точностью 83%.

В ходе выполнения бакалаврской работы было опубликовано две статьи на тему практического применения алгоритмов машинного обучения [17-20].

Основные результаты работы были доложены на IV Международной научно-практической конференции (школы-семинара) молодых ученых «Прикладная математика и информатика: современные исследования в области естественных и технических наук»

## 1 АНАЛИЗ СОСТОЯНИЯ ВОПРОСА

Контактная точечная сварка широко распространена во всех отраслях мировой промышленности. Отличительной особенностью контактной сварки является то, что она выполнена только в производственных условиях с использованием сварочных машин и роботов.

Производительность контактной сварки обеспечивается высокой скоростью протекания процесса – одно сварное соединение выполняется за десятые доли секунды. При этом качество сварки нестабильно из внешних случайных неконтролируемых воздействий. Поэтому актуальным вопросом на сегодняшний день остается разработка таких же высокопроизводительных способов контроля качества.

Современные способы контроля качества сварки основаны на методах машинного обучения, которые позволяют автоматизировать процесс настройки модели диагностики под любую номенклатуру свариваемых заготовок (различные толщины, материалы, критерии качества).

Таблица 1.1 – Интеллектуальные системы диагностики сварки [1].

<b>Авторы</b>	<b>Используемый математический аппарат</b>	<b>Принцип действия</b>
В.С. Климов, А.С. Климов, С.А. Петрушкин, А.Д. Шижгин.	Деревья принятия решений	На основе измеренных параметров сварки начиная от корня дерева, совершая последовательный переход от узла к узлу дерева с учетом располагающихся в них условий, осуществляется спуск к одному из листов. В листе дерева содержится метка предполагаемого класса качества

		сварного соединения.
V. Balendran, A. Aravinthan, D. Al-Dabass, K. Sivayoganathan.	Нейронная сеть прямого распространения	Данные об изменении сопротивления между электродами в процессе сварки подаются в двухслойную нейронную сеть прямого распространения. Во втором слое нейронной сети находится один нейрон выходной сигнал, которого указывает на прогнозируемое значение прочности соединения. В зависимости от прогнозируемой прочности делается заключение о классе качества сварки.
J. Rönning, P. Laurinen, L. Tuovinen, H. Junno.	Байесовские сети доверия	Характеристики осциллограмм сварочного тока и напряжения и напряжения подаются на вход Байесовские сети доверия. На выходе сети вычисляется вероятность принадлежности соединения к классу качественных сварок.
R.B. Chinnam, D. Filev, M. El- Banna.	Нейронные сети LVQ	Вектор измеренных значений сопротивления на участке между электродами подаются на вход нейронной сети. Входные сигналы взвешиваются с помощью весовых коэффициентов и передаются от слоя к слою сети. На выходе нейронной сети активизируется нейрон с номером класса качества сварного соединения



Для решения задачи диагностики сварки применяются такие методы машинного обучения, как нейронные сети прямого распространения, LVQ сети, рекуррентные нейронные сети, байесовские сети доверия, деревья классификации и регрессии.

Однако в настоящее время не существует исследований по применению алгоритма kNN в задачах диагностики контактной сварки.

Целью работы является автоматизация процесса диагностики сварки за счет разработки алгоритма построения классификатора качества сварных соединений, основанного на алгоритме машинного обучения kNN.

Для достижения поставленной цели в бакалаврской работе решаются следующие задачи:

1. Провести анализ состояния вопроса теме интеллектуальной диагностики сварки.
2. Разработать алгоритм построения способ классификации качества сварки с использованием алгоритма kNN. Протестировать предложенный алгоритм на реальных данных контактной сварки.
3. Спроектировать и разработать программное обеспечение, реализующее предложенные подходы.

## 2 РАЗРАБОТКА АЛГОРИТМА ДИАГНОСТИКИ КАЧЕСТВА СВАРКИ НА ОСНОВЕ АЛГОРИТМА KNN

### 2.1 Технология классификация данных с использованием алгоритма kNN

Метод ближайшего соседа является алгоритмом классификации данных, при котором класс  $y$  исследуемого объекта  $x$  определялся на основе наиболее близкого объекта обучающей выборки. Близость объектов оценивается с помощью выбранной метрики. Такая вариация алгоритма показывала низкую точность работы, что привело к появлению алгоритма kNN ( $k$ -ближайших соседей,  $k$ -nearest neighbor).

В алгоритме kNN класс исследуемого объекта  $x$  определяется на основе классов нескольких ближайших объектов  $x_i$  в количестве  $k$ . Недостатком такого подхода является частое возникновение ситуации не однозначности при классификации (например, когда среди  $k$  ближайших соседей исследуемого объекта половина относится к первому классу, а другая половина ко второму классу).

Решение данной проблемой является модификация алгоритма kNN для классификации исследуемого объекта, с учетом значений расстояний до ближайших соседей. В этом случае для каждого соседа с индексом  $i$  ( $i=1..k$ ) рассчитывается вес  $w_i$ , прямо пропорциональный расстоянию от данного соседа до исследуемого объекта. Тогда считается, что исследуемый объект принадлежит тому классу, суммарный вес которого имеет максимальное значение.

Математический аппарат алгоритма опирается на гипотезу компактности, которая утверждает, что если мера сходства объектов введена корректно, то схожие объекты чаще лежат в одном классе, чем в разных классах. При этом границы между классами имеют простую форму и классы образуют компактно локализованные области в пространстве объектов

(гипотеза компактности не связана с понятием компактных ограниченных замкнутых множеств из математического анализа).

Опишем математический аппарат данного алгоритма.

Исходными данными алгоритма является:

1. Обучающая выборка  $X^m$ , состоящая из объектов  $x_1 \dots x_m$  с одинаковым набором атрибутов. Для всех объектов должны быть известны значения атрибутов и принадлежность их классам  $y_1 \dots y_m$ . Атрибуты могут быть числовыми или категориальными. Таким образом, обучающая выборка задана так:

$$X^m = \{(x_1, y_1), \dots, (x_m, y_m)\} \quad (2.1)$$

2. Метрика  $\rho(x, x')$  расчёта расстояний между объектами. Можно использовать одну из известных метрик – Евклида, Чебышева, Минковского, расстояние Манхэттена и др.

3. Объект  $u$ , для которых необходимо определить принадлежность их к одному из классов.

Относительно классифицируемого объекта  $u$  объекты  $x_1 \dots x_m$  обучающей выборки сортируются в порядке увеличения расстояния:

$$\rho(u, x_{1;u}) < \rho(u, x_{2;u}) < \dots < \rho(u, x_{m;u}), \quad (2.2)$$

где  $x_{i;u}$  - объект обучающей выборки, являющийся  $i$ -ым соседом по отношению к классифицируемому объекту. В результате сортировки порождается новая нумерация объектов обучающей выборки.

Тогда результат работы алгоритма kNN по отношению к классифицируемому объекту  $u$  можно представить так:

$$a(u) = \arg \max_{y \in Y} \sum_{i=1}^m [y(x_{i;u}) = y] w(i, u), \quad (2.3)$$

где  $y_{i;u}$  - метка класса  $i$ -ого соседа классифицируемого объекта.  $w(i, u)$  – весовая функция, для оценки степени влияния  $i$ -ого объекта на результата классификации объекта  $u$ .

От способа задания весовой функции зависит реализация алгоритма

kNN:

- $w(i, u) = [i = 1]$  – метод ближайшего соседа (графическая интерпретация метода представлена на рисунке 2.1);

- $w(i, u) = [i \leq k]$  – метод k ближайших соседей (графическая интерпретация метода представлена на рисунке 2.2);

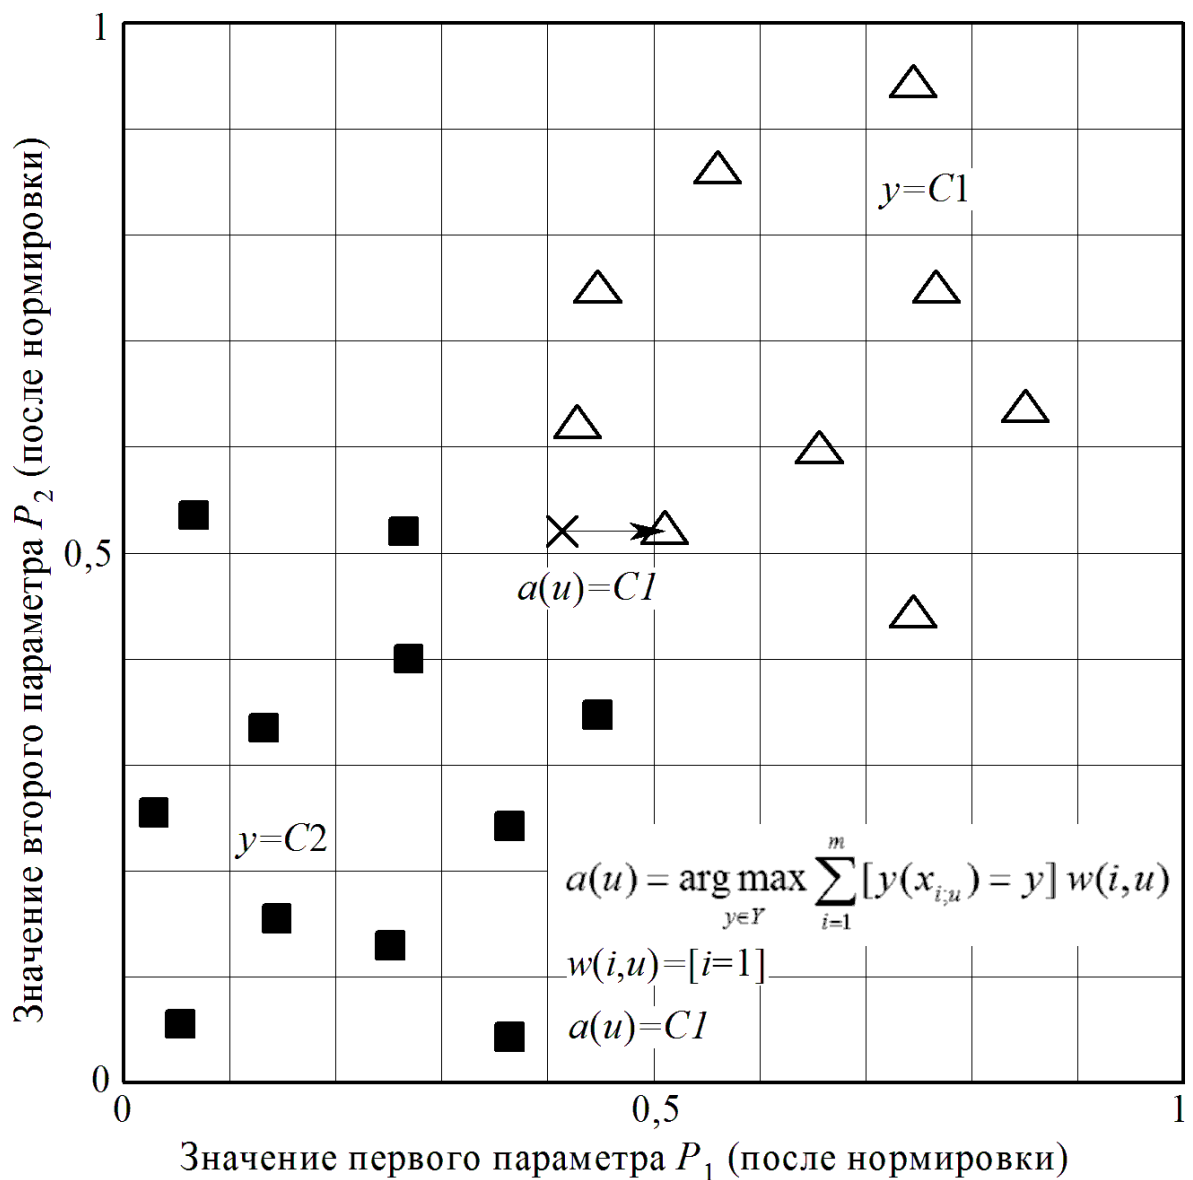
- $w(i, u) = [i \leq k]q^i$  – метод k экспоненциально взвешенных ближайших соседей, где предполагается  $q < 1$ ;

- $w(i, u) = K\left(\frac{\rho(u, x_{i;u})}{h}\right)$  – метод парзеновского окна фиксированной ширины  $h$  ;

- $w(i, u) = K\left(\frac{\rho(u, x_{i;u})}{\rho(u, x_{k+1;u})}\right)$  – метод парзеновского окна переменной ширины;

- $w(i, u) = K\left(\frac{\rho(u, x_{i;u})}{h(x_{i,u})}\right)$  – метод потенциальных функций, в котором ширина окна  $h(x_i)$  зависит не от классифицируемого объекта, а от обучающего объекта  $x_i$ .

Здесь  $K(r)$  – заданная неотрицательная монотонно невозрастающая функция на  $[0, +\infty)$ , ядро сглаживания. Графическая интерпретация методов с использованием  $K(r)$  представлена на рисунке 2.3.



C1 – метка первого класса (объекты обозначены символом « $\Delta$ »);


C2 – метка второго класса (объекты обозначены символом « $\blacksquare$ »);

$u$  – классифицируемый объект (обозначен символом « $\times$ »);

$w(i,u)$  – весовая функция оценки степени важности  $i$ -ого соседнего объекта

$a(u)$  – алгоритм классификации;

Рисунок 2.1 – Графическая интерпретация метода ближайшего соседа



C1 – метка первого класса (объекты обозначены символом « $\Delta$ »);

C2 – метка второго класса (объекты обозначены символом « $\blacksquare$ »);

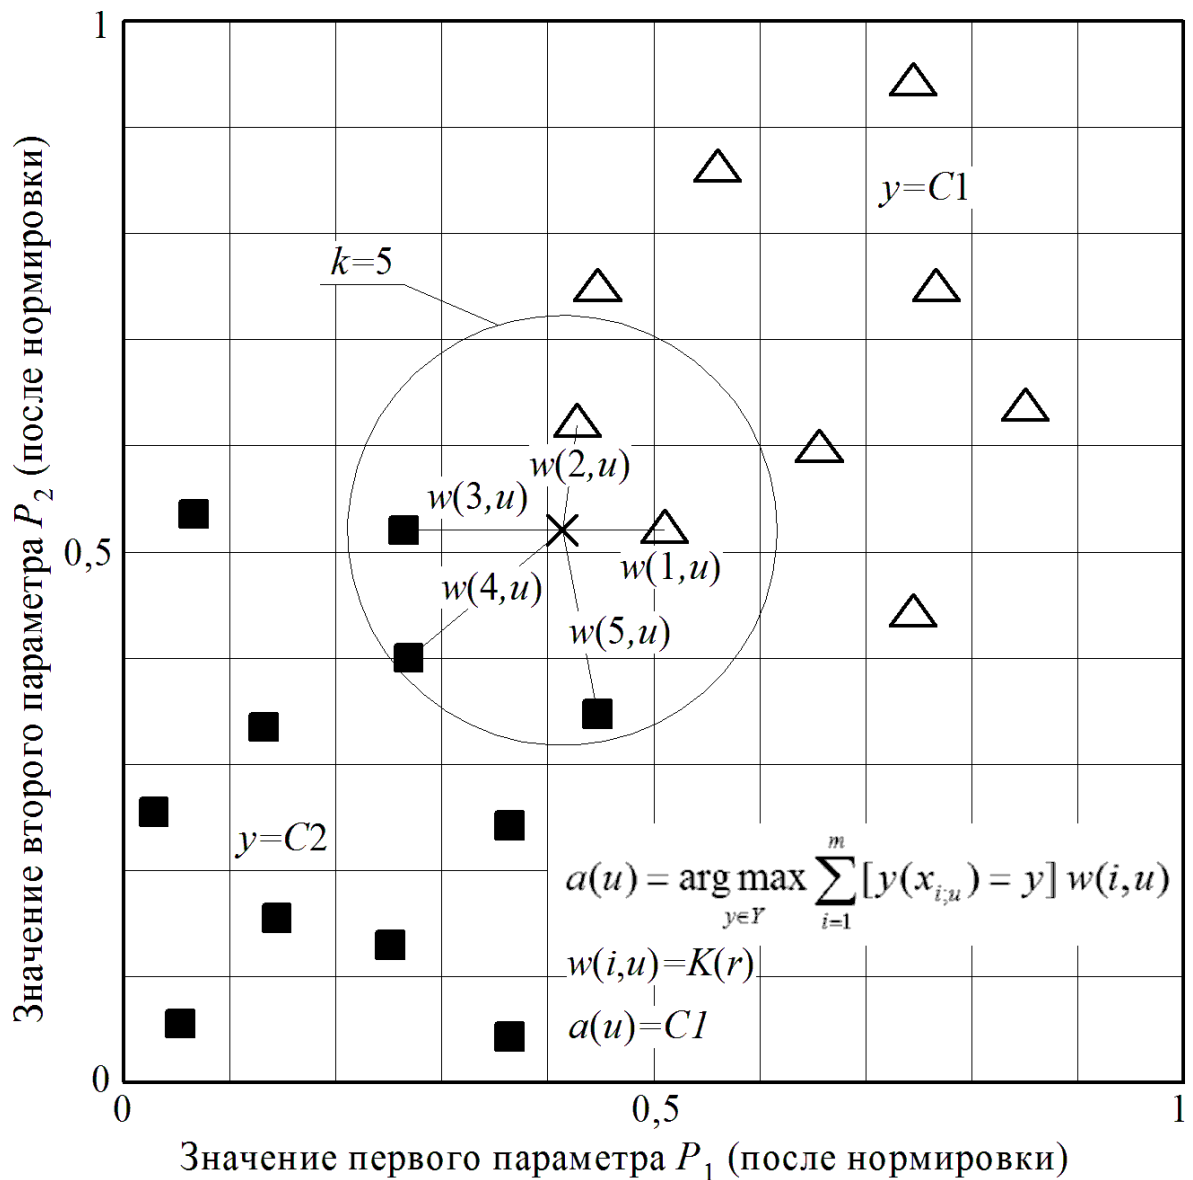
$u$  – классифицируемый объект (обозначен символом « $\times$ »);

$w(i, u)$  – весовая функция оценки степени важности  $i$ -ого соседнего объекта;

$k$  – количество учитываемых соседних объектов;

$a(u)$  – алгоритм классификации;

Рисунок 2.2 – Графическая интерпретация метода  $k$  ближайших соседей



C1 – метка первого класса (объекты обозначены символом « $\Delta$ »);

C2 – метка второго класса (объекты обозначены символом « $\blacksquare$ »);

$u$  – классифицируемый объект (обозначен символом « $\times$ »);

$w(i,u)$  – весовая функция оценки степени важности  $i$ -ого соседнего объекта;

$k$  – количество учитываемых соседних объектов;

$a(u)$  – алгоритм классификации;

Рисунок 2.3 – Графическая интерпретация метода  $k$  ближайших соседей с учетом расстояния от классифицируемого объекта и его ближайших соседей

Использование алгоритма kNN при классификации объектов сопряжено с рядом проблем. Например, с проблемой определения оптимального значения параметра  $k$ . Так при  $k=1$  результат классификации становится неустойчивым к шумовым значениям в обучающей выборке. При  $k=m$  ( $m$  – количество объектов в обучающей выборке) алгоритм теряет свою гибкость и часто выдает один и тот же результат (метку класса). Определить оптимальное значение  $k$  для каждого конкретного случая можно только опытным путем.

Другой проблемой алгоритма является необходимость очистки обучающей выборки от неинформативных объектов. Это выражается в том, что один информативный объект может быть окружен очень близкими по характеристикам объектами того же класса. Такая избыточность приводит, во-первых, к увеличению длительности расчетов при решении задачи классификации и, во-вторых, отрицательно сказывается на точности работы алгоритма kNN. Таким образом, для эффективного использования алгоритма kNN необходимо разработать алгоритм очистки обучающей выборки от неинформативных объектов.

Другой проблемой алгоритма kNN является сложность технической реализации классификации объекта при больших размерах обучающей выборки (при  $m \gg 10^3$ ). Это связано с тем, что для классификации объекта необходимо хранить все объекты обучающей выборки. Данная проблема решается путем организации индексов и использования структур данных, подходящих для быстрого поиска ближайших объектов (*kd*-деревья).

Другой проблемой алгоритма kNN является выбор оптимальной метрики, для расчета сходства между объектами. Использование различных метрик может в некоторых случаях приводить к различным результатам классификации объекта.

В качестве метрик могут использоваться, например:

- метрика Евклида:



$$\|x - x'\|_2 = ((x_1 - x'_1)^2 + (x_2 - x'_2)^2 + \dots + (x_n - x'_n)^2)^{\frac{1}{2}} \quad (2.4)$$

- прямоугольная метрика:

$$\|x - x'\|_1 = (|x_1 - x'_1| + |x_2 - x'_2| + \dots + |x_n - x'_n|) \quad (2.5)$$

- метрика Чебышева:

$$\|x - x'\|_\infty = \max(|x_1 - x'_1|, |x_2 - x'_2|, \dots, |x_n - x'_n|) \quad (2.6)$$

Определить какая из метрик позволит обеспечить максимальную точность возможно только опытным путем. Чаще всего в качестве удачной метрики априори принимают метрику Евклида.

Достоинствами метрических алгоритмов типа kNN.

- Простота реализации и возможность введения различных модификаций.
- Возможность интерпретировать классификацию объекта путём предъявления пользователю ближайшего объекта или нескольких. «Прецедентная» логика работы алгоритма хорошо понятна экспертам в таких предметных областях, как медицина, биометрия, юриспруденция, и др.

Недостатки простых метрических алгоритмов типа kNN.

- Приходится хранить обучающую выборку целиком. Это приводит к неэффективному расходу памяти и чрезмерному усложнению решающего правила. При наличии погрешностей (как в исходных данных, так и в модели сходства  $\rho$ ), это может приводить к понижению точности классификации вблизи границы классов. Имеет смысл отбирать минимальное подмножество опорных объектов, действительно необходимых для классификации.
- Поиск ближайшего соседа «в лоб» требует сравнения классифицируемого объекта со всеми объектами выборки за  $O(\ell)$  операций. Для задач с большими выборками это может оказаться накладно.

## 2.2 Анализ данных процесса контактной сварки

В исследовании рассматривается проблема диагностики качества контактной сварки. Результатом процесса сварки является сварная точка, качество которой необходимо прогнозировать.

Измеряемыми в процессе каждой сварки параметрами являются – значения коэффициента мощности  $\cos\varphi$  в каждом периоде сетевого напряжения. Т.е. каждая сварка описывается вектором значений  $(\cos\varphi_1, \cos\varphi_2, \dots, \cos\varphi_m)$ .

Существуют исследования [1], направленные на обоснование связи между динамикой изменения коэффициента мощности  $\cos\varphi$  в процессе сварки и металлургическими процессам, происходящими между электродами (нагрев, плавление, кристаллизация). При этом в исследованиях отмечается важность не абсолютных значений  $\cos\varphi$ , а динамика изменений значений в процессе сварки.




Рисунок 2.3 – Пример нормировки данных сварки

Для того чтобы диагностировать сварку по динамике изменения  $\cos\varphi$  в процессе сварки вектор значений  $(\cos\varphi_1, \cos\varphi_2, \dots, \cos\varphi_m)$  нормируется в масштабах одной сварки к диапазону от 0 до 100. Таким образом, получаем вектор значений  $(P_1, P_2, \dots, P_m)$ , где значение 0 соответствует минимальному значению  $\cos\varphi$ , а 100 максимальному значению  $\cos\varphi$  за сварку (рисунок 2.3).

В нашем распоряжении имеются данные сварки пакета заготовок из низкоуглеродистой стали. Пакет состоит из двух листов толщиной по 0,8 миллиметров каждый, расположенные внахлест. При этом длительность сварки – 9 периодов сетевого напряжения (поэтому вектор входных параметров  $(P_1, P_2, \dots, P_9)$  состоит из 9 значений). Все экспериментальные соединения подвергались тестированию на разрывной машине для определения максимальной силы  $F_{пр}$  разрушения сварки. Пример экспериментальных данных представлен в таблице 2.1.

Таблица 2.1 – Фрагмент экспериментальных данных, после нормировки значений  $\cos \varphi_i$

№	$P_1$	$P_2$	$P_3$	$P_4$	$P_5$	$P_6$	$P_7$	$P_8$	$P_9$	$F_{пр}, Н$
1	61,83	85,40	100	100	32,53	16,67	0	0	0	4267
2	100	74,67	65,60	65,60	65,60	65,60	21,34	10,94	0	4267
3	83,82	17,59	83,82	100	100	100	100	17,59	0	4238
4	87,50	66,32	100	66,32	59,01	59,01	17,05	8,74	0	5171
5	62,17	93,74	100	68,66	93,74	62,17	15,98	8,19	0	5278
6	93,18	58,79	93,18	100	65,86	51,33	51,33	8,48	0	5739
7	76,26	71,37	100	80,95	76,26	42,13	36,56	30,72	0	6141
8	100	84,51	80,30	80,30	51,66	46,84	11,73	6,00	0	6553
9	94,50	100	100	100	64,33	58,32	14,61	7,47	0	6347
10	74,75	94,61	100	100	63,84	58,03	14,13	7,23	0	6471
11	88,99	100	100	100	63,84	20,71	7,23	0	0	6661
12	94,85	83,99	100	83,99	62,35	36,40	29,22	4,33	0	6671
13	100	100	100	75,18	45,80	36,94	5,30	0	0	7014
14	80,55	97,20	100	60,78	50,59	25,79	21,64	0	12,73	6377
15	93,74	100	100	100	75,74	47,47	13,83	4,81	0	7014
16	93,19	100	82,19	79,84	58,92	37,22	11,27	3,92	0	7122
17	84,35	100	88,481	70,73	49,77	27,44	21,11	17,73	0	7240
...					...					
100	100	76,61	33,39	36,36	22,71	19,49	5,624	1,94	0	8191

Для подготовки выборки экспериментальных данных для решения задачи классификации необходимо выполнить перемаркировку данных. Для этого введем следующие метки класса: С1 – качественная сварка, С2 –

некачественная сварка. Следует отметить, что меток класса может быть и больше, в зависимости от решаемой задачи.

Критерий качества сварки можно выбирать любым, но в нашем случае сварку будем считать качественной, если сила разрушения сварного соединения больше значения 6800 Н. В остальных случаях сварка будет считаться некачественной.

Результата перемаркировки данных представлен в таблице 2.2.

Таблица 2.2 – Результат перемаркировки данных (С1 – качественная сварка, С2 – некачественная сварка)

№	$P_1$	$P_2$	$P_3$	$P_4$	$P_5$	$P_6$	$P_7$	$P_8$	$P_9$	Класс
1	61,83	85,40	100	100	32,53	16,67	0	0	0	C2
2	100	74,67	65,60	65,60	65,60	65,60	21,34	10,94	0	C2
3	83,82	17,59	83,82	100	100	100	100	17,59	0	C2
4	87,50	66,32	100	66,32	59,01	59,01	17,05	8,74	0	C2
5	62,17	93,74	100	68,66	93,74	62,17	15,98	8,19	0	C2
6	93,18	58,79	93,18	100	65,86	51,33	51,33	8,48	0	C2
7	76,26	71,37	100	80,95	76,26	42,13	36,56	30,72	0	C2
8	100	84,51	80,30	80,30	51,66	46,84	11,73	6,00	0	C2
9	94,50	100	100	100	64,33	58,32	14,61	7,47	0	C2
10	74,75	94,61	100	100	63,84	58,03	14,13	7,23	0	C2
11	88,99	100	100	100	63,84	20,71	7,23	0	0	C2
12	94,85	83,99	100	83,99	62,35	36,40	29,22	4,33	0	C2
13	100	100	100	75,18	45,80	36,94	5,30	0	0	C1
14	80,55	97,20	100	60,78	50,59	25,79	21,64	0	12,73	C2
15	93,74	100	100	100	75,74	47,47	13,83	4,81	0	C1
16	93,19	100	82,19	79,84	58,92	37,22	11,27	3,92	0	C1
17	84,35	100	88,481	70,73	49,77	27,44	21,11	17,73	0	C1
...					...					
100	100	76,61	33,39	36,36	22,71	19,49	5,624	1,94	0	C1

Теперь полученные данные, представленные в таблице 2.2 можно использовать для построения классификатора качества с помощью алгоритма kNN

## 2.3 Алгоритм диагностики качества контактной сварки на основе алгоритма kNN

Предложенный алгоритм диагностики качества состоит из трех этапов:

1. Накопление экспериментальных данных для построения классификатора качества сварки.
2. Построение классификатора качества.
3. Классификация качества сварки с использованием алгоритма kNN.

Рассмотрим каждый этап по отдельности.

На первом этапе алгоритма необходимо накопить базу экспериментальных данных процесса контактной сварки. При этом в процессе каждой отдельной сварки необходимо измерять те параметры, по которым впоследствии будет проводиться диагностика сварки. Сварку нужно проводить таким образом, чтобы в наборе экспериментальных данных была как качественная сварка, так и обязательно некачественная сварка. В идеальном случае соотношении качественной и некачественной сварки в таблице экспериментальных данных должны быть 50% на 50% (допускаются отклонения от данных пропорций).

Полученные сварные соединения должны быть изучены в лабораторных условиях для оценки соответствия каждого из них на соответствие выбранным критериям качества (в нашем случае сварка считается качественной, если сила разрушения сварного соединения больше значения 6800 Н).

Так как в последствии при классификации качества сварки будет использован алгоритм kNN, то учитывая его особенности работы все измеренные входные параметры необходимо нормировать к диапазону от [0, 1] или [0, 100]. Нормировка необходима, чтобы при расчете расстояния по выбранной метрике, влияние каждого отдельного параметра на результат было одинаковым. Пример результата выполнения первого этапа представлен в таблице 2.2.

На втором этапе производится построения классификатор для классификации данных с использованием алгоритма kNN. Фактически выполнения данного этапа сводится к прореживанию обучающей выборки путем определения опорных объектов (сварок) на основе которых будет проводиться классификация качества сварок. Это связано с необходимостью очистки обучающей выборки от неинформативных объектов (данная особенность описана в разделе «Технология классификация данных с использованием алгоритма kNN» бакалаврской работы).

Процедуру очистки обучающей выборки от неинформативных объектов предложено выполнять следующим образом:

- разделить область определения выходного параметра  $F_{пр}$  на равные диапазоны (с одинаковым шагом). В нашем случае область определения  $F_{пр}$  [4800; 8200] Н. Ширина каждого диапазона – 200 Н. Таким образом количество диапазонов – 18 штук.

- взять из каждого диапазона  $F_{пр}$  по одному объекту обучающей выборки.

Результат выполнения данного этапа – классификатор, работающий по алгоритму kNN на основе данных представленных в таблице 2.3.

На третьем этапе с использование полученного классификатора осуществляется классификация качества сварного соединения, описанного вектором входных параметров  $(P_1, P_2, \dots, P_9)$ .

Таблица 2.3 – Данные, на основе которые работает классификатор качества сварки.

№	$P_1$	$P_2$	$P_3$	$P_4$	$P_5$	$P_6$	$P_7$	$P_8$	$P_9$	$C$
1	100	68,81	17,47	19,91	19,91	19,91	19,91	4,42	0	C1
2	100	76,61	33,39	36,36	22,71	19,5	5,62	1,95	0	C1
3	100	82,87	51,04	42,35	25,61	21,89	6,5	2,25	0	C1
4	100	78,82	45,67	37,82	36,07	21,21	17,28	15,2	0	C1
5	93,78	100	86,89	53,71	29,79	24,92	5,86	0	0	C1
6	84,36	100	88,49	70,73	49,78	27,45	21,11	17,74	0	C1
7	93,19	100	82,19	79,85	58,93	37,22	11,28	3,92	0	C1
8	96,7	100	100	76,27	68,98	44,3	10,04	0	0	C1
9	81,42	97,33	100	65,5	56,17	32,9	25,12	4,44	0	C2
10	94,09	100	100	100	65,05	58,66	15,41	7,88	0	C2
11	94,5	100	100	100	64,34	58,33	14,61	7,48	0	C2
12	76,27	71,38	100	80,96	76,27	42,13	36,56	30,72	0	C2
13	93,89	100	100	61,72	55,1	48,14	48,14	7,91	0	C2
14	80,79	93,89	100	61,72	55,1	48,14	7,91	0	0	C2
15	93,38	65,6	100	65,6	58,69	16,25	8,32	0	0	C2
16	62,17	93,74	100	68,67	93,74	62,17	15,99	8,19	0	C2
17	87,51	66,32	100	66,32	59,02	59,02	17,05	8,74	0	C2
18	100	81,2	76,52	76,52	47,8	42,44	36,8	6,44	0	C2

Пример работы полученного классификатора и исследование его точности на данных тестовой выборки приведены в третьей главе бакалаврской работы.

### 3 ПРАКТИЧЕСКАЯ РЕАЛИЗАЦИЯ ПРЕДЛОЖЕННЫХ РЕШЕНИЙ

#### 3.1 Апробация алгоритма на данных контактной сварки

Приведем пример классификации качества сварки, описываемой следующим вектором входных параметров  $\mathbf{P}_x$  :

$$\mathbf{P}_x = (86,05; 100; 86,05; 61,55; 35,59; 28,64; 8,05; 0; 0) \quad (3.1)$$

При классификации данного объекта будет использоваться обучающая выборка с данными контактной сварки, представленная в таблице 2.3.

Описание вектора входных значений, выбранный критерий качества сварки, значения меток классов С1 и С2 подробно описаны во второй главе бакалаврской работы. Тем не менее, для удобства восприятия работы напомним, что вектор входных значений  $(P_1, P_2, \dots, P_9)$  - это нормированные значения, описывающие изменение коэффициента мощности в процессе сварки, С1 – класс качественных сварных соединения, С2 – класс некачественных сварных соединений. Критерий качества сварки – предельная сила разрушения сварного соединения  $>6800$  Н. Цель классификации – предсказать к какому классу качества относится исследуемое соединение, описанное вектором входных значений  $\mathbf{P}_x$ .

На первом этапе классификации рассчитаем расстояние от  $\mathbf{P}_x$  до всех объектов обучающей выборки с использованием выбранной метрики. В нашем случае мы будем использовать метрику Евклида (хотя при использовании метрик Манхэттена результат классификации не изменится).

Результат расчёта расстояния от исследуемого объекта до объектов обучающей выборки представлен в таблице 3.1



Таблица 3.1 – Расстояние от исследуемого объекта  $P_x$  до объектов обучающей выборки, рассчитанное с использованием метрики Евклида

<b>№ объекта обучающей выборки</b>	<b>Расстояние до объекта</b>	<b>Метка класса</b>
1	89,92816	C1
2	66,39441	C1
3	47,27448	C1
4	56,63803	C1
5	13,19036	C1
6	27,94794	C1
7	32,32595	C1
8	43,46424	C1
9	31,49206	C2
10	60,19352	C2
11	59,59238	C2
12	71,27072	C2
13	51,83442	C2
14	31,94782	C2
15	46,20617	C2
16	74,10211	C2
17	54,61725	C2
18	45,50815	C2

На следующем этапе классификации производится сортировка объектов обучающей выборки в порядке увеличения расстояния до исследуемого объекта. Результат сортировки представлен в таблице 3.2

Таблица 3.2 – Результат сортировки объектов обучающей выборки

<b>№ объекта обучающей выборки</b>	<b>Расстояние до объекта</b>	<b>Метка класса</b>
5	13,19036	C1
6	27,94794	C1
9	31,49206	C2
14	31,94782	C2
7	32,32595	C1
8	43,46424	C1
18	45,50815	C2
15	46,20617	C2
3	47,27448	C1
13	51,83442	C2
17	54,61725	C2
4	56,63803	C1
11	59,59238	C2
10	60,19352	C2
2	66,39441	C1
12	71,27072	C2
16	74,10211	C2
1	89,92816	C1

Теперь определим метку класса исследуемого объекта на основе меток класса ближайших  $k$  объектов. Объекту присевается та метка класса, объектов из которого больше среди  $k$  ближайших. В тех случаях, когда среди  $k$  объектов одинаковое количество записей относящихся к классу C1 и записей относящихся к классу C2 исследуемому объекту будет присвоена на

основе ожидания наихудшего результата сварки, т.е. метка С2 (некачественная сварка).

Результат выполнения данного этапа представлен в таблице 3.3.

Таблица 3.3 – Результат классификации объекта  $P_x$  в зависимости от параметра  $k$

Значение параметра $k$	Номера объектов с меткой С1	Номера объектов с меткой С2	Количество объектов с меткой С1	Количество объектов с меткой С2	Результат классификации
1	5	-	1	0	С1
2	5, 6	-	2	0	С1
3	5, 6	9	2	1	С1
4	5, 6	9, 14	2	2	С2
5	5, 6, 7	9, 14	3	2	С1
6	5, 6, 7, 8	9, 14	4	2	С1
7	5, 6, 7, 8	9, 14, 18	4	3	С1
8	5, 6, 7, 8	9, 14, 18, 15	4	4	С2
9	5, 6, 7, 8, 3	9, 14, 18, 15	5	4	С1
10	5, 6, 7, 8, 3	9, 14, 18, 15, 13	5	5	С2
11	5, 6, 7, 8, 3	9, 14, 18, 15, 13, 17	5	6	С2
12	5, 6, 7, 8, 3, 4	9, 14, 18, 15, 13, 17	6	6	С2
13	5, 6, 7, 8, 3, 4	9, 14, 18, 15, 13, 17, 11	6	7	С2
14	5, 6, 7, 8, 3, 4	9, 14, 18, 15, 13, 17, 11,	6	8	С2

		10			
15	5, 6, 7, 8, 3, 4, 2	9, 14, 18, 15,13,17, 11, 10	7	8	C2
16	5, 6, 7, 8, 3, 4, 2	9, 14, 18, 15,13,17, 11, 10, 12	7	9	C2
17	5, 6, 7, 8, 3, 4, 2	9, 14, 18, 15,13,17, 11, 10, 12, 16	7	10	C2
18	5, 6, 7, 8, 3, 4, 2, 1	9, 14, 18, 15,13,17, 11, 10, 12, 16	8	10	C2

Как видно из таблицы 3.3 результат классификации объекта во многом зависит от параметра  $k$  (количество ближайших соседей на основе которых определятся метка класса исследуемого объекта). Поэтому необходимо провести исследования по определению оптимального значения параметра  $k$ , обеспечивающего максимальную точность работы классификатора.

### **3.2 Исследование точности работы классификатора в зависимости от параметра $k$**

Была исследована точность работы классификатора качества сварки пр различных значениях параметра  $k$  (количество ближайших соседей на основе которых определятся метка класса исследуемого объекта). При этом использовались такие методы, как:

- cross-validation (перекрестная проверка), при которой исследуемые данные разбивались на мять частей. Из них четыре части использовались для обучения модели классификации данных, а одна часть

для проверки точности классификации. Данное исследование проводилось пять раз, при этом изменялось назначение частей (при этом только каждая из пяти частей по одному разу используется для проверки точности);

- *leave-one-out* (контроль по отдельным объектам), при которой все объект кроме одно используются для обучения классификатора, один единственный объект для проверки точности работа классификатора. Исследование точности продолжается до тех пор, пока каждый объект выборки не побывает в роли контрольного (для проверки точности) объекта.

- Проверка точности работы классификатора на объектах обучающей выборки. Результаты такой проверки точности не могут являться окончательными, на их основе нельзя делать конечные выводы о точности работы классификатора качества сварки. Однако интересным является характер падения точности с увеличение параметра  $k$ .

- Проверка точности работы классификатора на тестовой выборке данных, не имеющей общих объектов с обучающей выборкой данных.

При использовании всех описанных методов были построены графики отражающие зависимость точности работы классификатора от параметра  $k$  (рисунки 3.1-3.4).




Рисунок 3.1 – Точность классификации по методу Cross-Validation




Рисунок 3.2 – Точность классификации по методу Leave-one-out




Рисунок 3.3 – Точность классификации на обучающей выборке данных




Рисунок 3.4 – Точность классификации на тестовой выборке данных

В ходе анализа полученных графиков было установлено, что оптимальным значением  $k$  (количество ближайших соседей на основе которых определятся метка класса исследуемого объекта) при котором достигается максимальная точность рано трем ( $k=3$ ). При больших значениях точность классификации происходит снижение точности работы классификатора.

### **3.2 Программная реализация алгоритма диагностики**

При выполнении исследований для реализации предложенного алгоритма было разработано приложение (рисунок 3.5), обладающее следующими особенностями:

- наличие программная реализация алгоритма построения классификатора для классификации объектов методом kNN;
- наличие графического интерфейса;
- программное моделирование работы алгоритма kNN;
- импорт экспериментальных данных сварки из электронной таблицы Excel-файл;
- экспорт результатов тестирования классификатора на тестовой выборки в Excel файл для дальнейшего анализа точности работы.

Алгоритм работы с данным приложением следующий. Сначала необходимо импортировать в приложение экспериментальные данные контактной сварки. Для этого необходимо в пункте меню «Файл» выбрать подпункт «Открыть исходные данные». Содержимое пункта меню «Файл» представлено на рисунке 3.6.

После импорта экспериментальных данных в таблице, расположенной в левом верхнем углу главного окна программы отобразятся загруженные данные (рисунок 3.7).

-



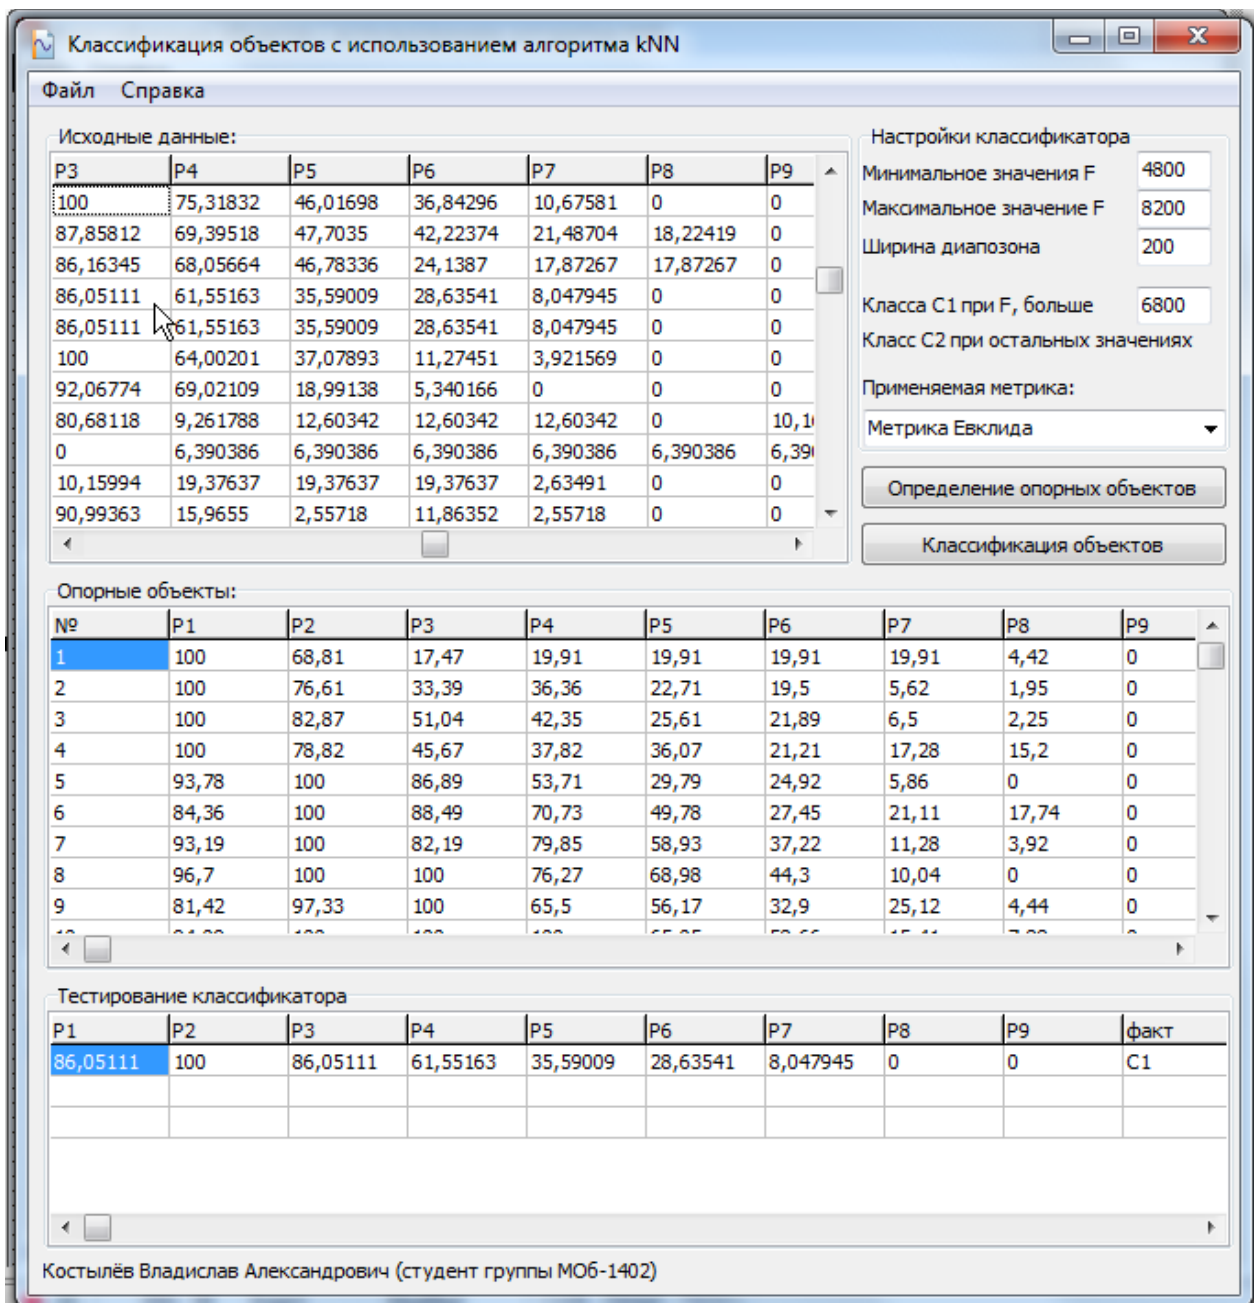


Рисунок 3.5 – Внешний вид приложения

Теперь можно переходить к заданию настроек классификатора. Для этого в группе элементов управления «настройки классификатора», расположенной в правом верхнем углу программы необходимо задать следующие параметры:

- область определения (максимальное и минимальное значение) выходного параметра (силы разрушения сварного соединения  $F$ );

- Ширина диапазона каждого отрезка области определения выходной переменной (необходимо для формирования множества опорных объектов);
- Пороговое значение выходного параметра, при котором объект относится к классу С1 (критерий качества сварки – сила разрушения сварного соединения больше 6800 Н).

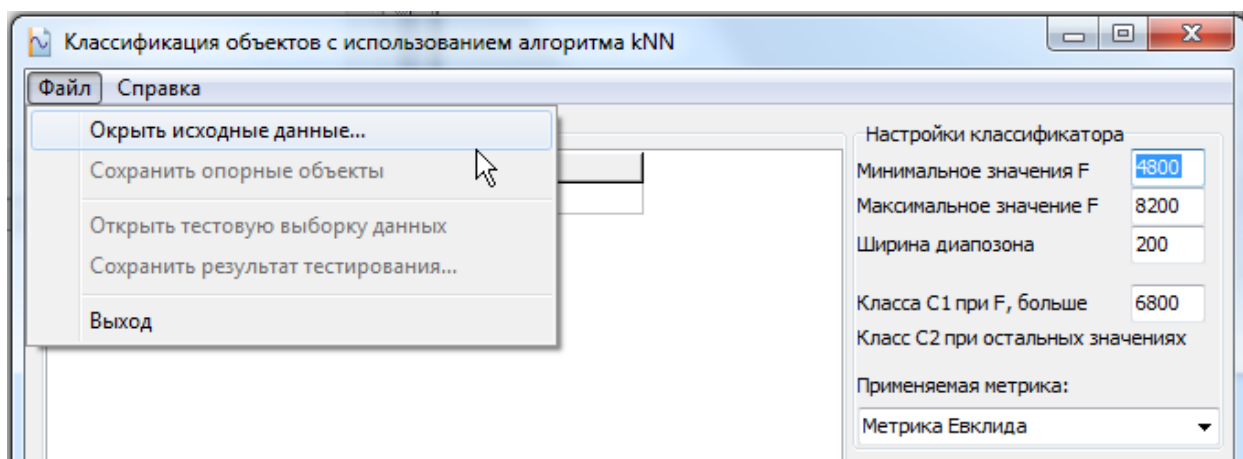


Рисунок 3.6 – Содержимое пункта меню «Файл»

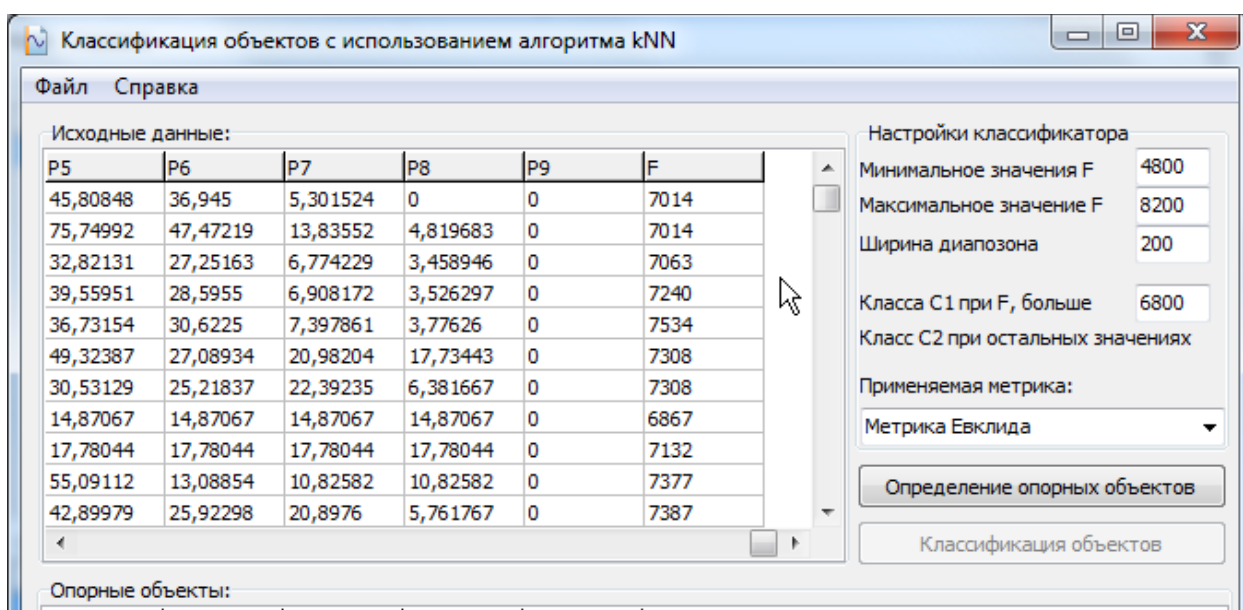


Рисунок 3.7 – Результат загрузки экспериментальных данных сварки из Excel-файла

Для запуска построения классификатора (нахождения множества опорных объектов и перемаркировки объектов с учетом заданного критерия качества) необходимо нажать на кнопку «Определение опорных объектов».

Результат выполнения данного этапа представлен на рисунке 3.8.

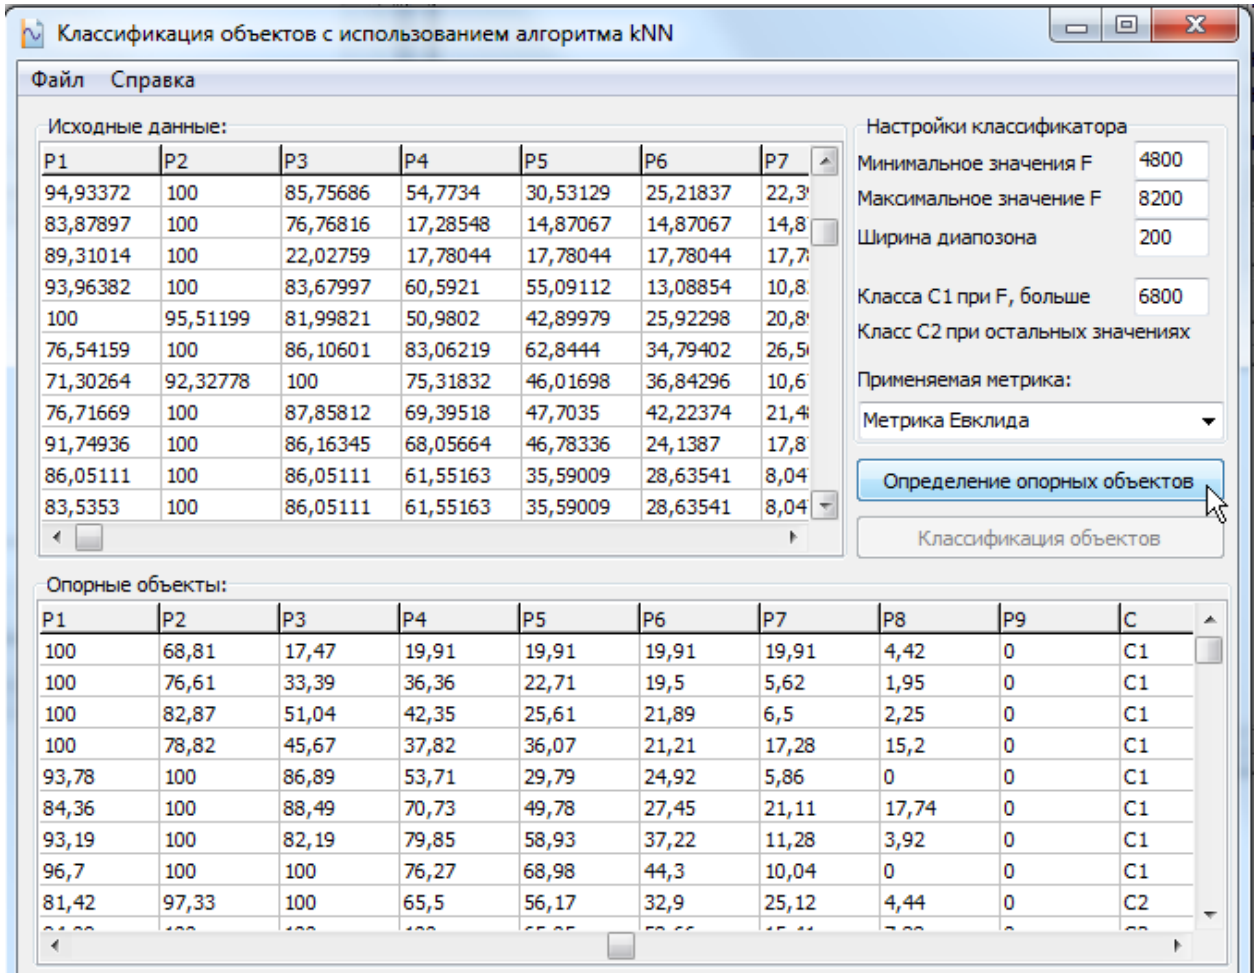


Рисунок 3.8 – Результат формирования множества опорных объектов, необходимых для классификации

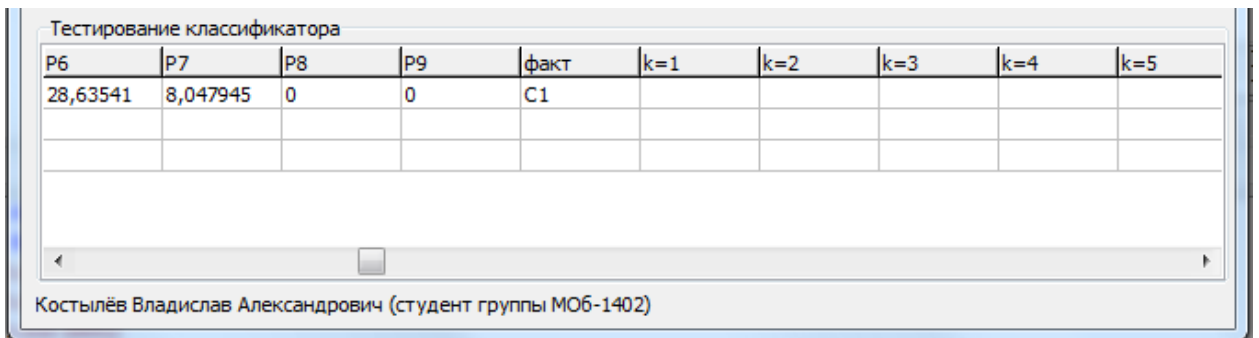


Рисунок 3.9 – Результат загрузки тестового объекта

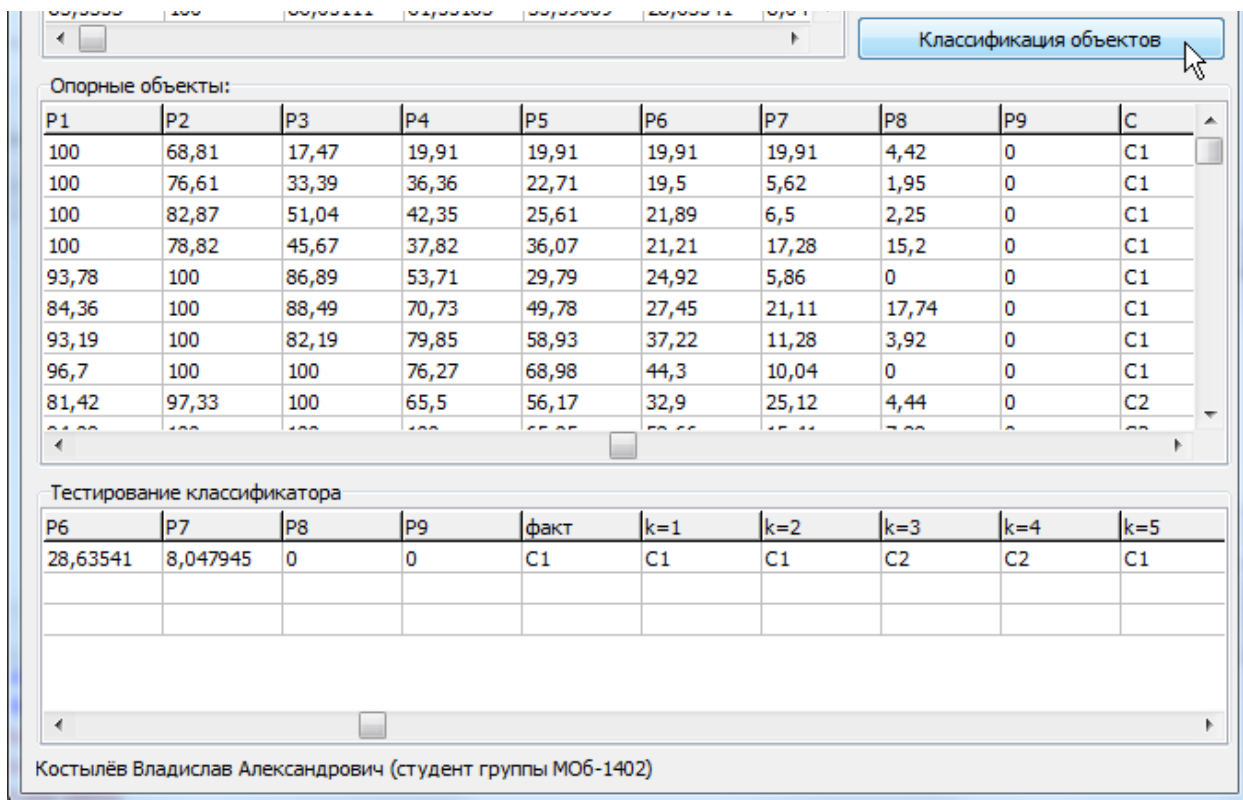


Рисунок 3.10 – Результат загрузки объекта при различных параметрах k

После того, как был сформирован классификатор качества сварки в виде множества опорных объектов можно перейти к его тестированию.

Для этого необходимо импортировать тестовую выборку данных из Excel файла. Для этого необходимо выбрать подпункт «Открыть тестовую выборку данных» в пункте «Файл» (рисунок 3.6). При этом загруженные данные отобразятся в таблице «Тестирование классификатора», расположенной в нижней части главного окна программы.

Теперь, нажав на кнопку «Классификация объектов» можно запустить процесс классификации. Результат классификации каждого объект будет для различных значений параметра k (количество соседей) (рисунок 3.10). При необходимости, результат классификации объекта можно сохранить в Excel файл для дальнейшего анализа точности работы классификатора.

## ЗАКЛЮЧЕНИЕ

По проведенным в бакалаврской работе исследованиям были сделаны следующие выводы:

1. В ходе проведенного литературного обзора установлено, что современные способы контроля качества сварки основаны на методах машинного обучения, которые позволяют автоматизировать процесс настройки модели диагностики под любую номенклатуру свариваемых заготовок (различные толщины, материалы, критерии качества). Для решения задачи диагностики сварки применяются такие методы машинного обучения, как нейронные сети прямого распространения, LVQ сети, рекуррентные нейронные сети, байесовские сети доверия, деревья классификации и регрессии.

2. В работе предложен способ диагностики качества сварки с использованием индуктивного алгоритма машинного обучения kNN. В работе описывается процедура подготовки обучающей выборки на основе экспериментальных данных процесса сварки, процедура построения и использования классификатора качества сварки.

3. Показан пример работы алгоритма классификации качества на реальных данных.

3. Предложенные подходы были протестированы на экспериментальных данных контактной сварки. Полученный в ходе исследований классификатор качества позволяет по параметрам описывающим динамику изменения коэффициента мощности  $\cos\varphi$  в процессе сварки оценивать класс качества сварных соединений с точность 83%, при этом оптимальное (с точки зрения точности работы классификатора) значение параметра  $k=3$ . При этом Критерий качества сварки – предельная сила разрушения сварного соединения  $>6800$  Н

4. В ходе выполнения исследований была разработана программа, позволяющая по данным экспериментальных сварок производить классификацию качества сварных соединений.

В ходе выполнения бакалаврской работы было опубликовано две статьи на тему практического применения алгоритмов машинного обучения [17-20].

Основные результаты работы были доложены на IV Международной научно-практической конференции (школы-семинара) молодых ученых «Прикладная математика и информатика: современные исследования в области естественных и технических наук»

## СПИСОК ИСПОЛЬЗУЕМОЙ ЛИТЕРАТУРЫ

1. Управление тепловыми и металлургическими процессами при контактной сварке с применением систем искусственного интеллекта : отчет о НИР (промежуточ.) / Тольяттинский государственный университет; рук. Климов В. С. – Тольятти, 2016. – 50 с. – Исполн.: Климов А. С., Кудинов А. К. – № ГР 115020230051.
2. Shang, W. An Improved kNN Algorithm – Fuzzy kNN / Wenqian Shang, Houkuan Huang, Haibin Zhu, Yongmin Lin, Zihai Wang, Youli Qu // International Conference on Computational and Information Science: Computational Intelligence and Security (CIS 2005). – Springer-Verlag Berlin Heidelberg, 2005. – pp. 741-746
3. Łukasik, M. Threshold ML-KNN: Statistical Evaluation on Multiple Benchmarks / Michał Łukasik, Marcin Sydow // 20th International Conference on Language Processing and Intelligent Information Systems (IIS 2013). – Springer-Verlag Berlin Heidelberg, 2013. – pp. 198-205
4. Deegalla, S. Classification of Microarrays with kNN: Comparison of Dimensionality Reduction Methods / Sampath Deegalla, Henrik Boström // International Conference on Intelligent Data Engineering and Automated Learning (IDEAL 2007). – Springer-Verlag Berlin Heidelberg, 2007. – pp. 800-809
5. Gayar, N. A Study of the Robustness of KNN Classifiers Trained Using Soft Labels / Neamat El Gayar, Friedhelm Schwenker, Günther Palm // IAPR Workshop on Artificial Neural Networks in Pattern Recognition (ANNPR 2006). – Springer-Verlag Berlin Heidelberg, 2006. – pp. 67-80
6. Terzi, M. Text-Based User-kNN: Measuring User Similarity Based on Text Reviews / Maria Terzi, Matthew Rowe, Maria-Angela Ferrario, Jon Whittle // International Conference on User Modeling, Adaptation, and Personalization (UMAP 2014). – Springer International Publishing Switzerland, 2014. – pp. 195-206

7. Fu, J. H. A Multi-Strategy Approach to KNN and LARM on Small and Incrementally Induced Prediction Knowledge / Jui-Hsi Fu, Sing-Ling Lee // International Conference on Advanced Data Mining and Applications (ADMA 2009). – Springer-Verlag Berlin Heidelberg, 2009. – pp. 453-460
8. Zhang, X. Multi-modal Image Fusion with KNN Matting / Xia Zhang, Hui Lin, Xudong Kang, Shutao Li // Chinese Conference on Pattern Recognition (CCPR 2014). – Springer-Verlag Berlin Heidelberg, 2014. – pp. 89-96
9. Rashad, M. Isolated Printed Arabic Character Recognition Using KNN and Random Forest Tree Classifiers / Marwa Rashad, Noura A. Semary // International Conference on Advanced Machine Learning Technologies and Applications (AMLTA 2014). – Springer International Publishing Switzerland, 2014. – pp. 11-17
10. Zhang, S. Efficient kNN Algorithm Based on Graph Sparse Reconstruction / Shichao Zhang, Ming Zong, Ke Sun, Yue Liu, Debo Cheng // International Conference on Advanced Data Mining and Applications (ADMA 2014). – Springer International Publishing Switzerland, 2014. – pp. 356-369
11. Hamed, M. G. Possibilistic KNN Regression Using Tolerance Intervals / Mohammad Ghasemi Hamed, Mathieu Serrurier, Nicolas Durand // International Conference on Information Processing and Management of Uncertainty in Knowledge-Based Systems: Advances in Computational Intelligence (IPMU 2012). – Springer-Verlag Berlin Heidelberg, 2012. – pp. 410-419
12. Wajeed, M. A. Using KNN Algorithm for Text Categorization / M. A. Wajeed, T. Adilakshmi // First International Conference on Computational Intelligence and Information Technology (CIIT 2011). – Springer-Verlag Berlin Heidelberg, 2011. – pp. 796-801
13. Miloud-Aouidate, A. A Hybrid KNN-Ant Colony Optimization Algorithm for Prototype Selection / Amal Miloud-Aouidate, Ahmed Riadh Baba-Ali // International Conference on Neural Information Processing (ICONIP 2012). – Springer-Verlag Berlin Heidelberg, 2012. – pp. 307-314



14. Jitkar, B. D. Effectively Implementation of KNN-Search on Multidimensional Data Using Quadtree / B. D. Jitkar, S. D. Raut, S. T. Patil // Proceedings of Third International Conference on Information Systems Design and Intelligent Applications (INDIA 2016). – Springer India, 2016. – pp. 111-118

15. Ishii, N. Text Classification: Combining Grouping, LSA and kNN vs Support Vector Machine / Naohiro Ishii. Takeshi Murai, Takahiro Yamada, Yongguang Bao, Susumu Suzuki // International Conference on Knowledge-Based and Intelligent Information and Engineering Systems (KES 2006). – Springer-Verlag Berlin Heidelberg, 2006. – pp. 393-400

16. Liao, Z. KNN Based Evolutionary Techniques for Updating Query Cost Models / Zhining Liao, Hui Wang, David Glass, Gongde Guo // International Conference on Fuzzy Systems and Knowledge Discovery (FSKD 2005). – Springer-Verlag Berlin Heidelberg, 2005. – pp. 797-800

17. Костылев, В.А. Применение машинного обучения с подкреплением для поиска оптимальных параметров [Текст] / В.А. Костылев, С.Р. Никитин // IV Международной научно-практической конференции (школы-семинара) молодых ученых «Прикладная математика и информатика: современные исследования в области естественных и технических наук». – Тольятти: Изд. ТГУ, 2018.

18. Костылев, В.А. Применение нейронных сетей прямого распространения для прогнозирования прочности сварных соединений [Текст] / Д.А. Александров, В.А. Костылев // IV Международной научно-практической конференции (школы-семинара) молодых ученых «Прикладная математика и информатика: современные исследования в области естественных и технических наук». – Тольятти: Изд. ТГУ, 2018.

19. Костылев, В.А. Построение регрессионной модели для прогнозирования прочности сварного соединения / В.А. Костылев, Д.А. Александров // IV Международной научно-практической конференции (школы-семинара) молодых ученых «Прикладная математика и

информатика: современные исследования в области естественных и технических наук». – Тольятти: Изд. ТГУ, 2018.

20. Костылев, В.А. Реализация алгоритмов машинного обучения в среде MATLAB / С.Р. Никитин, В.А. Костылев // IV Международной научно-практической конференции (школы-семинара) молодых ученых «Прикладная математика и информатика: современные исследования в области естественных и технических наук». – Тольятти: Изд. ТГУ, 2018.