

ИДЕНТИФИКАЦИЯ ОПАСНЫХ ЖИДКОСТЕЙ С ПОМОЩЬЮ МИКРОВОЛНОВЫХ СИСТЕМ И ИЗВЕСТНЫХ АЛГОРИТМОВ КЛАССИФИКАЦИИ

© 2020 г. Эбру Эфеоглу¹, Гуркан Туна^{1,*}

¹Университет Тракия, Эдирне, Турция

*E-mail: gurkantuna@trakya.edu.tr

Поступила в редакцию 26.05.2020; после доработки 09.06.2020

Принята к публикации 11.06.2020

В последнее время наблюдается увеличение числа террористических атак, осуществляемых с использованием жидких взрывчатых веществ, что привело к важности разработки быстрых и надежных методов, позволяющих различать опасные жидкости и жидкости, которые используются в этих взрывчатых веществах. Поскольку стабильность и чувствительность микроволновых систем высоки, диапазон СВЧ-частот является предпочтительным, чтобы различить опасные жидкости от безопасных. В данной работе для разработки классификационного подхода, который можно использовать в жидкостных сканерах, предлагается бесконтактная система, основанная на измерениях вторичного электромагнитного поля жидкостей в микроволновом диапазоне частот. Наивный байесовский анализ, линейный дискриминантный анализ, качественный анализ данных, метод опорных векторов, последовательная минимальная оптимизация, алгоритмы классификации К-ближайших соседей используются для классификации жидкостей, а эффективность их классификации подвергается анализу. Результаты ряда классификационных экспериментов подтверждают применимость предложенного метода измерения. Как показывают результаты, метод К-ближайших соседей является наиболее подходящим алгоритмом классификации для распознавания опасных жидкостей. Поскольку его можно легко реализовать и процесс является быстрым, система классификации, основанная на предлагаемом подходе, может быть очень полезна в аэропортах и торговых центрах.

Ключевые слова: опасные жидкости, микроволны, классификация, алгоритмы классификации, эффективность.

DOI: 10.31857/S0130308220090067

1. ВВЕДЕНИЕ

Многие исследователи изучали влияние промышленных отходов и опасных веществ на окружающую среду и здоровье человека. Воздействие опасных веществ проявляется во многих сферах, таких как здравоохранение, безопасность, военное дело и промышленность. Жидкости, которые легко доступны в повседневной жизни, также являются угрозой безопасности человека и окружающей среды. Они особенно предпочтительны для террористических атак в таких местах, как аэропорты, вокзалы, остановки транспорта, политические митинги, торговые центры, концерты и другие культурные мероприятия, где присутствуют тысячи людей. Таким образом, должны обязательно проводиться работы по распознаванию опасных жидкостей для предотвращения террористических атак.

В последние годы в связи с ростом числа террористических атак некоторые авторы исследовали способы обнаружения опасных веществ и незаконных предметов, а также проанализировали существующие системы, связанные с ними методы, их преимущества и недостатки. В результате, было создано общая картина того, что можно сделать для предотвращения угроз атак [1]. Основным направлением этих исследований была разработка систем, которые могут автоматически обнаруживать взрывчатое вещество без оператора. Таким образом, за последние несколько лет был достигнут значительный прогресс в разработке систем рентгеновской визуализации для обнаружения взрывчатых веществ. Как и системы рентгеновской визуализации, было тщательно изучено использование ядерного квадрупольного резонанса (ЯКР) для обнаружения взрывчатых веществ [2,3]. ЯКР является спектроскопическим методом, который может обнаруживать взрывчатые вещества с высокой химической специфичностью [2]. Метод ядерного магнитного резонанса (ЯМР) использовался для исследования и классификации содержимых жидкостей в закрытых неметаллических контейнерах [4]. Для обнаружения жидких взрывчатых веществ была также предложена методика магнитно-резонансной томографии в ультраслабом поле [5].

В литературе для обнаружения взрывчатых веществ было предложено использовать различные методы, включая ядерный магнитный резонанс и рентген [6, 7]. Среди этих методов наиболее часто используемыми являются рентгеновские системы [7]. Рентгеновские системы также были

предложены для анализа неизвестных твердых образцов, которые могут содержать взрывчатые вещества, и анализа взрывчатых веществ на основе пероксида [8]. Наряду с ядерным магнитным резонансом и рентгеновским излучением, обнаружение и идентификацию жидкости можно проводить с помощью ТГц-спектроскопии во временной области [9]. Однако, хотя с помощью этих подходов очень легко обнаруживать определенные пероксидные соединения, они не могут различать многие типы жидкостей, используемых в повседневной жизни. Следовательно, существует необходимость в системе для распознавания этих жидкостей [6].

Микроволновые методы измерения широко используются для различных целей в нескольких областях, связанных с промышленностью и безопасностью. Например, эти методы были применены для снижения воздействия промышленных отходов и опасных материалов на окружающую среду, и были получены удовлетворительные результаты [10, 11]. Они также использовались для стабилизации ила [11]. Кроме того, было предложено использовать методы измерения коаксиальным зондом, которые являются одним из методов микроволновых измерений для обнаружения дефектов биопленки и проблем утонения стенок [12]. Распространение микроволн в жидкостях существенно отличается от их распространения в воздухе. В то же время, зависящие от частоты скорости и ослабления микроволн варьируются от жидкости к жидкости, в зависимости от ее молекулярного состава. Как известно, комплексные коэффициенты проницаемости и отражения и пропускания жидкостей различны. Полосы частот СВЧ и миллиметровых волн можно использовать для определения комплексных коэффициентов проницаемости, отражения и пропускания как твердых тел, так и жидкостей [13]. Для расчета относительной магнитной проницаемости материалов представлена формула, оптимизированная по алгоритму искусственной пчелиной колонии (ИПК) [14]. Они также могут быть использованы для определения других свойств, таких как химическая концентрация, содержание живых организмов и влажность [15], а так же для характеристики жидкостей. Определение параметров материала важно не только для приложений, связанных с безопасностью, но также для исследований и применений в пищевой, медицинской, биотехнической, строительной, медицинской и военной областях [15, 16]. Это также применяется для расчета проницаемости жидкостей, коэффициента отражения S_{11} и коэффициента пропускания S_{21} [17, 18]. Хотя векторной сетевой анализатор и может обеспечить измерение фазы и величины в широком диапазоне микроволновых частот, он очень дорогой. Поэтому некоторые исследователи предпочитают модельные исследования [16].

В последнее десятилетие методы машинного обучения использовались для различных целей, таких как прогнозирование прочности бетона на сжатие [19], диагностика рака и заболеваний щитовидной железы [20, 21], классификация лекарств в соответствии с их концентрацией молока/плазмы [22], автоматическая классификация хороших и бракованных сельскохозяйственных продуктов и сырья, таких как рис, кофе и зеленый чай [23], классификация бензина [24] и оценка ботанического и географического происхождения меда [24]. В отличие от других применений и целей методов машинного обучения, в этом исследовании различные алгоритмы машинного обучения используются для классификации жидкостей на основе измерений S-параметров. Остальная часть этой статьи выглядит следующим образом. Методология и экспериментальная установка, используемые в этой статье, представлены во втором разделе. Алгоритмы классификации, используемые в этой статье, и метрики, используемые при оценке эффективности, также представлены в этом разделе. В третьем разделе представлены результаты исследования оценки эффективности. Наконец, заключение к данной статье находится в четвертом разделе.

2. ЭКСПЕРИМЕНТАЛЬНАЯ УСТАНОВКА И МЕТОДОЛОГИЯ ЭКСПЕРИМЕНТА

Различные методы измерения могут быть использованы для определения диэлектрических свойств материалов. Агрегатное состояние материала (газ, жидкость или твердое), частотный диапазон и температура (высокая или низкая) являются важными факторами при выборе наиболее подходящего метода измерения [26]. При коаксиальном зондовом методе электромагнитная волна проникает в жидкость с минимальным отражением [27]. Хотя метод коаксиального зонда может использоваться для измерений жидкостей, обычно это не практично, а иногда и опасно погружать что-либо в опасные жидкости или даже открывать крышку. С другой стороны, бесконтактная измерительная платформа, используемая в этом исследовании, позволяет проводить измерения, не открывая крышку жидкости и не погружая ничего в жидкость. Экспериментальная установка, использованная в этом исследовании для классификации жидко-




Рис. 1. Экспериментальная установка для классификации жидкостей.

стей с использованием микроволновой патч-антенны, показана на рис. 1. Она состоит из микроволновой патч-антенны круглой формы, подключенной к векторному сетевому анализатору, для измерения коэффициента отражения электромагнитной волны. Для создания экспериментальной установки была разработана антенна с резонансной частотой 1,5 ГГц. Конструкция была построена на диэлектрической подложке на основе стеклотекстолита FR4 высотой 1,6 мм, относительной диэлектрической проницаемостью 4,4 и экраном 10x10 см² под ней. Антенна питается через 50-омный коаксиальный электрический соединитель. Геометрия антенны показана на рис. 2, а фотографии антенны показаны на рис. 3.




Рис. 2. Конструкция антенны.




Рис. 3. Вид антенны спереди и сзади.

Диаметр антенны рассчитывался по уравнениям:

$$F = \frac{8,791x \cdot 10^9}{f_r \sqrt{\epsilon_r}}; \quad (1)$$

$$a = \frac{F}{\left\{ 1 + \frac{2h}{\pi \epsilon_r F \left[\ln \left(\frac{\pi F}{2h} \right) + 1,7726 \right]^{\frac{1}{2}}} \right\}}, \quad (2)$$

где ϵ_r — относительная диэлектрическая проницаемость подложки, f_r — резонансная частота, h — высота подложки, a — радиус лепестка.

Ход работы выглядел следующим образом. Коэффициент отражения электромагнитных волн от жидкостей измерялся при соблюдении расстояния между антенной и бутылкой примерно 5 мм. Затем была создана база данных по значениям для каждой жидкости. Набор данных в этой базе данных впоследствии использовался для классификации жидкостей. Таким образом, правильный ход алгоритмов при классификации жидкостей, найденных в базе данных, был проверен в процессе распознавания. Чтобы проверить успешность алгоритмов, была проведена 10-кратная перекрестная проверка и 5-кратная перекрестная проверка. Затем эффективность алгоритмов классификации была проанализирована с использованием различных показателей. Описанная методология показана на рис. 4.

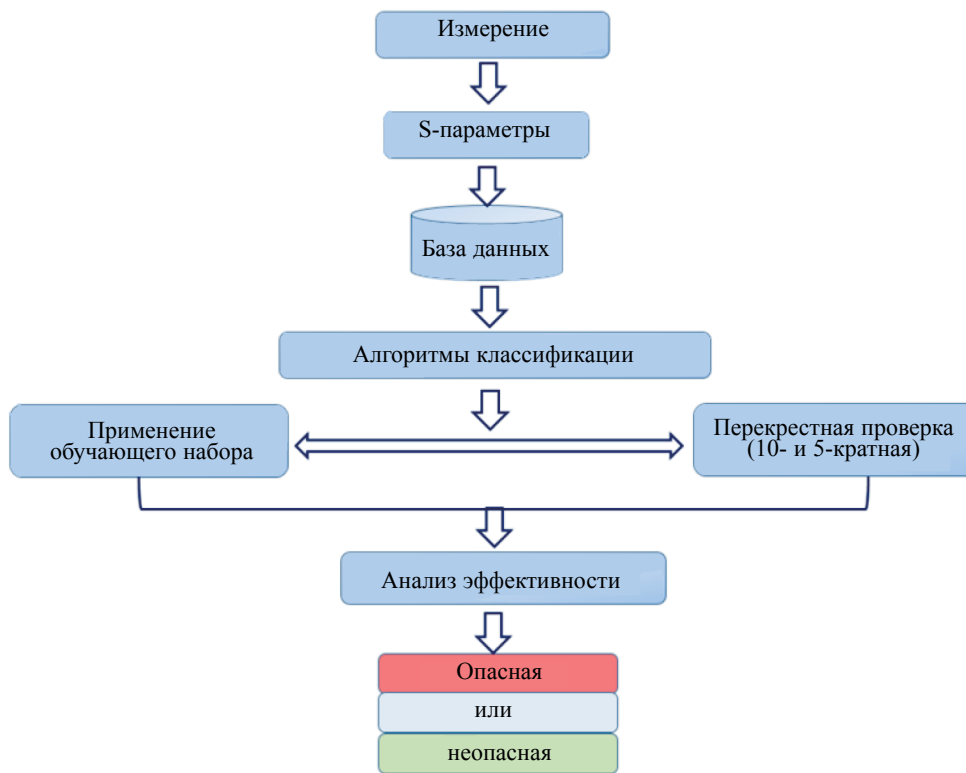


Рис. 4. Предложенная методология измерений.

2.1. Алгоритмы классификации и показатели эффективности

Машинное обучение используется для создания модели на основе существующих данных с использованием математических и статистических методов и для определения к какому классу относятся новые данные с максимально возможной точностью, используя эту модель. В этом исследовании в качестве классификаторов использовались наивный байесовский анализ, линейный дискриминантный анализ (ЛДА), качественный анализ данных (КАД), метод опорных векторов (МОВ), последовательная минимальная оптимизация (ПМО) и метод К-ближайших соседей (МКБС). Для оценки эффективности каждого классификатора были созданы матрицы неточностей.

Метод К-кратной перекрестной проверки был предпочтительным для оценки эффективности предложенной системы и алгоритмов классификации. Метод К-кратной перекрестной проверки разделяет набор данных на обучающие и тестовые наборы, чтобы избежать возможного переобучения и понять, как модель работает с набором данных, которые она не видела ранее. Потому что в задаче о переобучении модель дает хорошие результаты для обработанного набора данных, но делает неудачные прогнозы для новых наборов данных, которые она никогда не видела. Метод К-кратной перекрестной проверки делит обучающие данные на случайные К сегментов. К-1 используется для обучения, 1 часть используется для тестового набора, и К повторяется в этот раз. Значения, полученные в каждом раунде, суммируются, и оценивается эффективность модели. Число К обычно составляет 10 или 5 как в данной работе. Несколько показателей должны использоваться для оценки того, насколько хорошо классификатор работает в процесса классификации. В этом исследовании коэффициент Каппа, СКО, матрица неточностей и точность используются для оценки эффективности алгоритмов классификации.

Коэффициент Каппа. Это значение используется для измерения соответствия между прогнозируемым и наблюдаемым распределениями в группе данных. Расчет значения каппа приведен в (5). $P(a)$ обозначает точность алгоритма, а $P(e)$ представляет собой средневзвешенную величину ожидаемой точности алгоритма, по которому производится расчет на одном и том же наборе данных. Значение Каппа находится в диапазоне от -1 до 1. -1 означает полное несоответствие, то есть обратное соотношение, а 1 означает идеальное соответствие. Чем ближе значение к 1, тем больше соответствие и тем меньше разброс. Интерпретация значения коэффициента Каппа приведена в табл. 1.

Таблица 1

Величина коэффициента Каппа

Величина коэффициента Каппа	Примечание
<0	Несоответствие
0,0—0,20	Слабое соответствие
0,21—0,40	Среднее соответствие
0,41—0,60	Среднее соответствие
0,61—0,80	Сильное соответствие
0,81—1	Почти полное соответствие

$$K = \frac{P(a) - P(e)}{1 - P(e)}. \quad (3)$$

Среднеквадратическое отклонение (СКО). Он используется для масштабирования различий между фактическими и прогнозными значениями. Он определяется путем извлечения квадратного корня из среднеквадратической ошибки, как указано в (4). P представляет собой расчетные значения, a — истинные значения. Когда значение СКО приближается к нулю, увеличивается правильная оценка классификатора:

$$\text{СКО} = \sqrt{\frac{(P_1 - a_1)^2 + \dots + (P_n - a_{1n})^2}{n}}. \quad (4)$$

Матрица неточностей. Матрица неточностей содержит информацию о расчетных и истинных группах, составленных системой классификации. Диагональные элементы матрицы дают правильное количество классифицированных объектов.

Точность. Самый популярный и простой метод измерения эффективности модели — это точность модели. Точность, приведенная в (5), показывает количество образцов, правильно распознанных из всех образцов:

$$\text{Точность} = \frac{\text{Истинно положительное} + \text{Истинно отрицательное}}{\text{Количество значений}}. \quad (5)$$

3. ОЦЕНКА ЭФФЕКТИВНОСТИ

Для оценки эффективности была использована экспериментальная установка, описанная в разделе 2, для распознавания набора из 36 жидкостей. В табл. 2 приведен набор из 36 жидкостей, используемых экспериментальной установкой в данном исследовании, 12 из которых являются опасными, а 24 — неопасными и используются в повседневной жизни. Эти жидкости включают

Таблица 2

Исследуемые жидкости					
Опасные жидкости			Неопасные жидкости		
Этанол	1-пропанол	Персиковый сок	Шалгам	Ракия	Кола
Толуол	Метанол	Гель для душа	Шампунь	Шампанское	Чай
Бутанол	Ацетон	Пиво	Вода	Текила	Абрикосовый сок
Октанол	Одеколон	Гель для волос	Пахта	Виски	Кокосовое молоко
Растворитель	Уксусная кислота	Кетчуп	Джин	Водка	Уксус
Бензин	Изопропанол	Кондиционер для волос	Ликер	Молоко	Розовый сок

алкогольные напитки. В измерениях лучше использовать тонкую пластиковую бутылку объемом 0,5 л, которая имеет низкую отражательную способность и часто используется в повседневной жизни. Количество анализируемой жидкости должно быть примерно 7 см. Для единства измерений при одной и той же комнатной температуре во всех измерениях используется одна и та же бутылка. Результаты показаны на рис. 5. В этом исследовании, как указано в табл. 3, в зависимости от опасности для здоровья и свойств воспламенения для жидкостей указаны оценкой

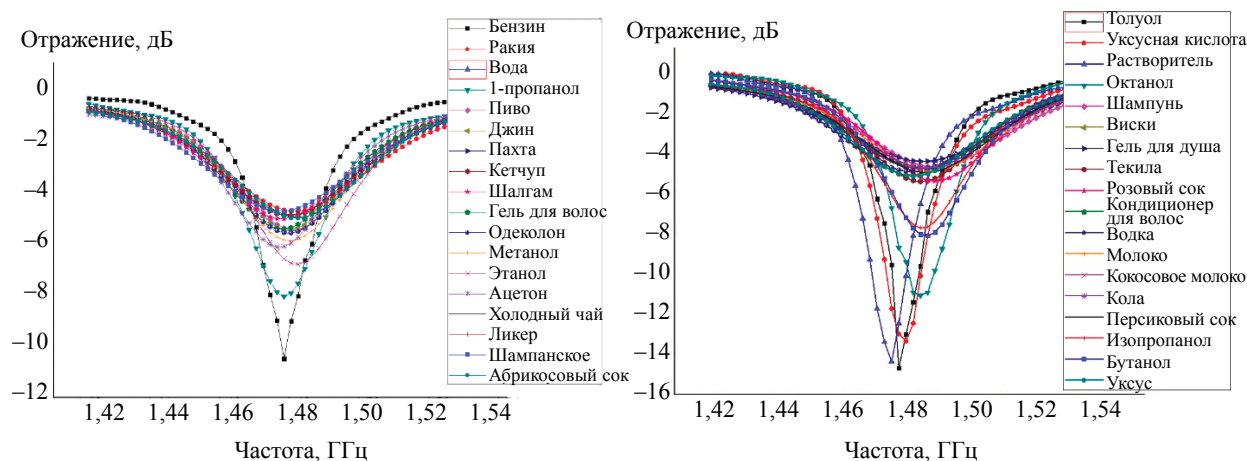


Рис. 5. Зависимость коэффициента отражения жидкостей от частоты.

Таблица 3

Свойства опасных жидкостей

Свойство	Опасность для здоровья	Воспламеняемость
Толуол	2	3
Бутанол	2	3
Растворитель	1	2
Октанол	1	2
Бензин	1	3
1-пропанол	1	3
Метанол	1	3
Ацетон	1	3
Этанол	2	3
Уксусная кислота	3	2
Изопропанол	1	3
Одеколон	2	3

от 0 до 4. Здесь: 0 означает отсутствие опасности, а 4 означает самую высокую опасность. Опасность для здоровья подразумевается относительно прямого орального применения или попадания на кожу. Высокая воспламеняемость материалов может привести к пожару или взрыву, который угрожает жизни человека.

При рассмотрении матрицы неточностей в наивном байесовском алгоритме (табл. 4) видно, что опасные жидкости были правильно классифицированы. В таблице зеленые области показывают количество правильно классифицированных жидкостей, а красные — количество неправильно классифицированных. В частности, когда в классификации использовался весь тренировочный набор, наивный байесовский метод правильно классифицировал все опасные жидкости, но распознал 6 неопасных жидкостей как опасные. Когда применялся процесс перекрестной проверки, наивный байесовский алгоритм классифицировал 1 опасную жидкость как неопасную и 5 неопасных жидкостей как опасные.

Таблица 4

Матрица неточностей — Наивный байесовский алгоритм

Обучающий набор	Факт (Общее)			10-кратная перекрестная проверка	Факт (Общее)			5-кратная перекрестная проверка	Факт (Общее)		
	+	-			+	-			+	-	
+	12	0	12	11	1	12	11	1	12		
-	6	18	24	5	19	24	5	19	24		
Прогноз (Общее)	18	18	36	16	20	36	16	20	36		

Таблица 5

Матрица неточностей — ЛДА

Обучающий набор	Факт (Общее)			10-кратная перекрестная проверка	Факт (Общее)			5-кратная перекрестная проверка	Факт (Общее)		
	+	-			+	-			+	-	
+	12	0	12	11	1	12	11	1	12		
-	5	19	24	6	18	24	6	18	24		
Прогноз (Общее)	17	19	36	17	19	36	17	19	36		

Таблица 6

Матрица неточностей — КАД

Обучающий набор		+	-	Факт (Общее)	10-кратная перекрестная проверка	+	-	Факт (Общее)	5-кратная перекрестная проверка	+	-	Факт (Общее)
	+	12	0	12		12	12	0		12	12	0
-	5	19	24	24	5	19	24	5	19	24		
Прогноз (Общее)	17	19	36	36	17	19	36	17	19	36		

Таблица 7

Матрица неточностей — МОВ

Обучающий набор		+	-	Факт (Общее)	10-кратная перекрестная проверка	+	-	Факт (Общее)	5-кратная перекрестная проверка	+	-	Факт (Общее)
	+	0	12	12		12	0	12		12	0	12
-	0	24	24	24	0	24	24	0	24	24		
Прогноз (Общее)	0	36	36	36	0	36	36	0	36	36		

Таблица 8

Матрица неточностей — ПМО

Обучающий набор		+	-	Факт (Общее)	10-кратная перекрестная проверка	+	-	Факт (Общее)	5-кратная перекрестная проверка Validation	+	-	Факт (Общее)
	+	11	1	12		12	9	3		12	9	3
-	1	23	24	24	2	22	24	4	20	24		
Прогноз (Общее)	12	24	36	36	11	25	36	13	23	36		

Таблица 9

Матрица неточностей – МКБС

Обучающий набор		+	-	Факт (Общее)	10-кратная перекрестная проверка	+	-	Факт (Общее)	5-кратная перекрестная проверка	+	-	Факт (Общее)
	+	12	0	12		12	11	1		12	9	3
-	0	24	24	24	0	24	24	0	24	24		
Прогноз (Общее)	12	24	36	36	11	25	36	9	27	36		




Рис. 6. Среднее количество верно и неверно классифицированных образцов для каждого алгоритма классификации.

При использовании всего тренировочного набора, ЛДА правильно распознал 12 опасных жидкостей, а 5 неопасных жидкостей были ошибочно классифицированы как опасные. В случае перекрестной проверки 1 опасная жидкость и 6 неопасных жидкостей были классифицированы неправильно (табл. 5). Матрицы неточностей алгоритма КАД (табл. 6) очень похожа на матрицу алгоритма ЛДА. Тем не менее КАД является более стабильным, чем алгоритм ЛДА, потому что он дает те же результаты при классификации как на обучающем наборе, так и в процессе перекрестной проверки. Матрица неточностей алгоритма МОВ (табл. 7) указывает на то, что алгоритм МОВ не смог сформировать правильную модель. МОВ распознает все жидкости как неопасные. По сравнению с МОВ алгоритм ПМО показал лучшие результаты. В тренировочном наборе ПМО правильно классифицировал 11 опасных жидкостей и 23 неопасных жидкости. Когда для ПМО была выполнена перекрестная проверка, количество правильных решений уменьшилось (табл. 8). Среди всех алгоритмов классификации МКБС достиг высочайшей точности. Алгоритм МКБС правильно классифицировал все опасные и неопасные жидкости, когда использовались все данные для обучения. С другой стороны, при проведении перекрестной проверки 10-кратная перекрестная проверка приводила к неправильной классификации для 1 жидкости, а 5-кратная перекрестная проверка приводила к неправильной классификации для 3 жидкостей (табл. 9).

В табл. 10 приведены значения точности, коэффициента каппа и значения СКО всех алгоритмов классификации при использовании всего тренировочного набора и применении 10- и 5-кратного перекрестных проверок. Правильно и неправильно классифицированные случаи всех алгоритмов классификации показаны на рис. 6. Как видно на рис. 5, алгоритм МКБС обеспечил наибольшее количество правильных прогнозов и наименьшее количество неправильных прогнозов. Если принять во внимание табл. 10, то видно, что алгоритм МОВ

Таблица 10

Сравнение всех алгоритмов классификации

	Точность (%)			Коэффициент Каппа			СКО		
	Обучающий набор	10-кратная перекрестная проверка	5-кратная перекрестная проверка	Обучающий набор	10-кратная перекрестная проверка	5-кратная перекрестная проверка	Обучающий набор	10-кратная перекрестная проверка	5-кратная перекрестная проверка
Наивный Байес	83,33	83,33	83,3	0,66	0,65	0,65	0,40	0,40	0,40
ЛДА	86,11	80,55	80,55	0,71	0,60	0,60	0,36	0,38	0,38
КАД	86,11	86,11	86,11	0,71	0,71	0,71	0,32	0,38	0,36
МОВ	66,66	66,66	66,66	0	0	0	0,57	0,57	0,57
ПМО	94,44	86,11	83,33	0,87	0,68	0,65	0,23	0,37	0,40
МКБС	100	97,22	91,66	1	0,93	0,80	0,08	0,18	0,30

обеспечивает самый низкий уровень точности и наибольшее значение СКО. Наивный алгоритм Байеса, ЛДА и КАД имеют схожие результаты. Алгоритм ПМО показал высокую точность 94,4 % при работе с обучающей выборкой, однако, при применении перекрестной проверки его точность снизилась. Алгоритм МКБС имел наивысшую точность при обучении и даже при применении перекрестной проверки. Кроме того, алгоритм МКБС имел самое низкое СКО по сравнению с другими. Значение коэффициента Карра алгоритма МКБС было равно 1 для обучающего набора и близко к 1 во время перекрестной проверки. Это подтверждает успешность использования алгоритма МКБС.

4. ЗАКЛЮЧЕНИЕ

В последние годы рост числа террористических атак с использованием жидких взрывчатых веществ привел к необходимости разработки систем, которые могут легко и эффективно распознавать жидкости, которые могут использоваться во взрывчатых веществах, и неопасные жидкости. В этом исследовании предлагается метод бесконтактного обнаружения опасных жидкостей и оценивается эффективность алгоритмов классификации, которые могут использоваться в предлагаемом методе. Новизна предлагаемого подхода заключается в том, что, хотя классификация выполняется с использованием предложенного подхода, нет необходимости вскрывать сосуд для доступа к содержимому. После разработки прототипа системы на основе предложенного подхода его можно использовать в аэропортах, торговых центрах и других местах. Благодаря простоте и скорости процесса предлагаемый подход, возможно, не приведет к образованию очередей при проверке и потере времени на досмотр службой безопасности. В дополнение к новому подходу по обнаружению опасных жидкостей, в этом исследовании была проанализирована работа шести различных алгоритмов классификации, используемых для идентификации опасных жидкостей, с точки зрения точности и временных требований. Как показывают результаты, МБКС является наиболее подходящим алгоритмом классификации для идентификации опасных жидкостей.

СПИСОК ЛИТЕРАТУРЫ

1. *Melnikov Y., Avtonomov P., Kornienko V., Olshansky Y.* Detection of Dangerous Materials and Illicit Objects in Cargoes and Baggage: Current Tools, Existing Problems and Possible Solutions // *Journal of Homeland Security and Emergency Management*. 2011. V. 8 (1). doi: 10.2202/1547-7355.1889
2. *Cardona L., Jiménez J., Vanegas N.* Nuclear quadrupole resonance for explosive detection // *Ingeniare Revista chilena de ingeniería*. 2015. V. 23 (3). P. 458—72.
3. *Miller J, Barrall G.* Explosives Detection with Nuclear Quadrupole Resonance // *American Scientist*. 2005. V. 93 (1). P. 50.
4. *Kumar S.* Liquid-contents verification for explosives, other hazards, and contraband by magnetic resonance // *Applied Magnetic Resonance*. 2004. V. 25 (3—4). P. 585—97. doi: 10.1007/BF03166550
5. *Espy M., Flynn M., Gomez J., Hanson C., Kraus R., Magnelind P.* et al. Ultra-low-field MRI for the detection of liquid explosives // *Superconductor Science and Technology*. 2010. V. 23 (3). P. 034023. doi: 10.1088/0953-2048/23/3/034023
6. *Abidin Z.Z., Omar F.N., Yogarajah P., Biak D.R.A., Man Y.B.C.* Dielectric characterization of liquid containing low alcoholic content for potential halal authentication in the 0.5-50 GHz range // *American Journal of Applied Sciences*. 2014. Jan. 11(7). P. 1104—12. doi: 10.3844/ajassp.2014.1104.1112
7. *Singh S., Singh M.* Explosives detection systems (EDS) for aviation security // *Signal Processing*. 2003. V. 83 (1). P. 31—55. doi: 10.1016/S0165-1684(02)00391-2
8. *Schulte-Ladbeck R., Vogel M., Karst U.* Recent methods for the determination of peroxide-based explosives // *Analytical and Bioanalytical Chemistry*. 2006. V. 386 (3). P. 559—65. doi: 10.1007/s00216-006-0579-y
9. *Choi K., Hong T., Sim K.I., Ha T., Park B.C., Chung J.H.* et al. Reflection terahertz time-domain spectroscopy of RDX and HMX explosives // *Journal of Applied Physics*. 2014. V. 115 (2). P. 023105. doi: 10.1063/1.4861616
10. *Windgasse G., Dauerman L.* Microwave Treatment of Hazardous Wastes: Removal of Volatile and Semi-Volatile Organic Contaminants from Soil // *Journal of Microwave Power and Electromagnetic Energy*. 1992. V. 27 (1). P. 23—32. doi: 10.1080/08327823.1992.11688167
11. *Mudhoo A., Sharma S.K.* Microwave Irradiation Technology in Waste Sludge and Wastewater Treatment Research // *Critical Reviews in Environmental Science and Technology*. 2011. V. 41 (11). P. 999—1066. doi: 10.1080/10643380903392767
12. *Liu L.* Application of Microwave for Remote NDT and Distinction of Biofouling and Wall Thinning Defects Inside a Metal Pipe // *Journal of Nondestructive Evaluation*. 2015. Feb. V. 34 (4). doi: 10.1007/s10921-015-0313-9
13. *Lucic B., Basic I., Nadramija D., Milicevic A., Trinajstic N., Suzuki T.* et al. Correlation of liquid viscosity with molecular structure for organic compounds using different variable selection methods // *Arkivoc*. 2002. V. 2002 (4). P. 45. doi: 10.3998/ark.5550190.0003.406
14. *Tekbas M., Toktas A., Ustun D.* A Formulaic Model Calculating the Permittivity of Testing Materials Placed on a Circular Patch Antenna. 2019 XXIVth International Seminar/Workshop on Direct and Inverse Problems of Electromagnetic and Acoustic Wave Theory (DIPED), 2019. doi:10.1109/DIPED.2019.8882582
15. *Büyükköztürk O., Yu T.-Y., Ortega J.A.* A methodology for determining complex permittivity of construction materials based on transmission-only coherent, wide-bandwidth free-space measurements // *Cement and Concrete Composites*. 2006. V. 28 (4). P. 349—59. doi: 10.1016/j.cemconcomp.2006.02.004

16. *Al-Mously S.I.Y.* A modified complex permittivity measurement technique at microwave frequency // *Int. J. New Comput. Archit. Appl.* 2012. V. 2. P. 389—401.
 17. *Li Z., Haigh A., Soutis C., Gibson A., Sloan R.* A Simulation-Assisted Non-destructive Approach for Permittivity Measurement Using an Open-Ended Microwave Waveguide // *Journal of Nondestructive Evaluation.* 2018. V. 37 (3). doi: 10.1007/s10921-018-0493-1
 18. *Jiang Y., Ju Y., Yang L.* Nondestructive In-situ Permittivity Measurement of Liquid Within a Bottle Using an Open-Ended Microwave Waveguide // *Journal of Nondestructive Evaluation.* 2015. Oct. V. 35 (1). doi: 10.1007/s10921-015-0322-8
 19. *Derousseau M., Lafichiev E., Kasprzyk J., Rajagopalan B., Srubar W.* A comparison of machine learning methods for predicting the compressive strength of field-placed concrete // *Construction and Building Materials.* 2019. V. 228. P. 116661. doi: 10.1016/j.conbuildmat.2019.08.042
 20. *Aydın E.A., Keleş M.K.* Breast cancer detection using K-nearest neighbors data mining method obtained from the bow-tie antenna dataset // *International Journal of RF and Microwave Computer-Aided Engineering.* 2017. V. 27 (6). doi: 10.1002/mmce.21098
 21. *Prasad V., Rao T.S., Babu M.S.P.* Thyroid disease diagnosis via hybrid architecture composing rough data sets theory and machine learning algorithms // *Soft Computing.* 2015. V. 20 (3). P. 1179—89. doi: 10.1007/s00500-014-1581-5
 22. *Fatemi M.H., Ghorbanzad'E M.* Classification of drugs according to their milk/plasma concentration ratio // *European Journal of Medicinal Chemistry.* 2010. V. 45 (11). P. 5051—5. doi: 10.1016/j.ejmech.2010.08.013
 23. *Kim S., Kwak J., Ko B.* Automatic Classification Algorithm for Raw Materials using Mean Shift Clustering and Stepwise Region Merging in Color // *Journal of Broadcast Engineering.* 2016. V. 21 (3). P. 425—35. doi: 10.5909/JBE.2016.21.3.425
 24. *Balabin R.M., Safieva R.Z., Lomakina E.I.* Gasoline classification using near infrared (NIR) spectroscopy data: Comparison of multivariate techniques // *Analytica Chimica Acta.* 2010. V. 671 (1—2). P. 27—35. doi: 10.1016/j.aca.2010.05.013
 25. *Maione C., Barbosa F., Barbosa R.M.* Predicting the botanical and geographical origin of honey with multivariate data analysis and machine learning techniques: A review // *Computers and Electronics in Agriculture.* 2019. V. 157. P. 436—46. doi: 10.1016/j.compag.2019.01.020
 26. *Dos Santos J.C.A., Dias M.H.C., Aguiar A., Borges Jr. I.* Using the coaxial probe method for permittivity measurements of liquids at high temperatures // *J. Microwaves, Optoelectron. Electromagn. Appl.* 2009. V. 8. P. 78—91.
 27. *Mitani T., Hasegawa N., Nakajima R., Shinohara N., Nozaki Y., Chikata T.* et al. Development of a wideband microwave reactor with a coaxial cable structure // *Chemical Engineering Journal.* 2016. V. 299. P. 209—16. doi: 10.1016/j.cej.2016.04.064
-