

# Методы машинного обучения для исследования звуков легких

Порева А.С., ORCID [0000-0002-3797-025X](https://orcid.org/0000-0002-3797-025X)

e-mail [porevanna@gmail.com](mailto:porevanna@gmail.com)

Вайтышин В.И., ORCID [0000-0002-8617-9042](https://orcid.org/0000-0002-8617-9042)

e-mail [valenook.ua@gmail.com](mailto:valenook.ua@gmail.com)

Карплюк Е.С., к.т.н., ORCID [0000-0002-4224-7760](https://orcid.org/0000-0002-4224-7760)

e-mail [yevgeniy@karplyuk.kiev.ua](mailto:yevgeniy@karplyuk.kiev.ua)

Кафедра электронной инженерии, Факультет Электроники

Национальный технический университет Украины

"Киевский политехнический институт имени Игоря Сикорского" [kpi.ua](http://kpi.ua)

Киев, Украина

*Реферат*—В статье рассматриваются основные методы машинного обучения с целью применения их к задаче классификации звуков легких. На основе базы звуков легких был получен ряд параметров сигналов. Задачей исследования было провести классификацию звуков при помощи пяти различных методов машинного обучения, а также определить из ряда параметров сигналов те из них, которые дают в конечном счете наивысшую точность. Таким образом было найдено семь наиболее диагностически ценных параметров звуков дыхания и выявлено, что два метода машинного обучения — метод опорных векторов и метод дерева принятия решений — показали наилучшие результаты. Таким образом, данная методика классификации может служить вспомогательным инструментом для врача-пульмонолога в постановке диагноза.

Библ. 18, табл. 5.

*Ключевые слова* — звуки легких; машинное обучение; классификатор; метод опорных векторов; метод дерева принятия решений.

## I. ВВЕДЕНИЕ

Легкие являются частью сложной системы жизнедеятельности человека. Расширяясь и сокращаясь тысячи раз каждый день, легкие выполняют важную функцию подачи в организм кислорода и выведения углекислого газа. Болезни легких могут быть результатом сбоев любой части этой системы. Чтобы вылечить болезни, очень важно правильно распознать болезни. Несмотря на бурное развитие устройств для диагностики, таких, как компьютерная томография (КТ), магнитно-резонансная томография (МРТ), ультразвуковое исследование, компьютерная аускультация, возникают новые проблемы; например, как обрабатывать и анализировать значительный объем данных, чтобы можно было получить высококачественную информацию для диагностики и лечения заболеваний [1]

Заболевания легких распространены по всему земному шару. Среди самых частых патологий дыхательной системы можно выделить [2]:

- ХОБЛ (хроническая обструктивная болезнь легких);
- туберкулез;
- респираторные инфекции нижних дыхательных путей;

- онкологию.

Для уверенной диагностики заболевания недостаточно ограничиться первичным осмотром, множество заболеваний имеют схожие симптомы. В противном случае эффективное лечение будет невозможно, что приведет к дальнейшему развитию болезни. В связи с этим врачи используют специальные методы диагностики, в частности, метод электронной аускультации.

Аускультация — это выслушивание звуков жизнедеятельности человека. Данный метод диагностики является наиболее простым и широко распространенным в медицинской практике методов функционального состояния организма человека [3].

Главной задачей метода аускультации является выявление характерных звуков в бронхо-легочной системе, сердце, желудочно-кишечном тракте и при некоторых повреждениях костей. При изучении состояния системы внешнего дыхания метод аускультации применяется для диагностики поражения легочной ткани и бронхов, плевры и переломов ребер.

Электронная аускультация представляет собой мощный метод диагностики, который позволяет выявлять и объективизировать характерные признаки заболеваний органов дыхания.



Развитие акустоэлектроники стимулировало применение электронных средств аускультации, а цифровая обработка звуковых сигналов вывели аускультацию на качественно новый научный уровень и позволяют осуществлять количественную оценку звуковых образов [4].

Благодаря электронной аускультации и различным современным методам цифровой обработки и анализа сигналов, таким, как частотный анализ [5], частотно-временной, вейвлет-анализ [6], [7], биспектральный анализ [8] и др., появилась возможность получать новые диагностически значимые параметры звуков дыхания. Однако ни один из существующих методов анализа звуков легких не является универсальным, потому поиск решений, основанных на новых методах анализа, является актуальной задачей.

Как было сказано, благодаря разнообразию методов анализа можно извлекать достаточно много параметров звуков дыхания, а потому становится актуальной задача оптимизации интерпретации полученных данных. Для этой цели прекрасно подходит так называемое машинное обучение.

Основная идея машинного обучения состоит в том, чтобы облегчить процесс обработки данных, вычленив именно ту информацию, которая будет полезна в диагностике, и на основании этой информации вынести вердикт.

Машинное обучение применяется в очень многих сферах, таких, как биоинформатика, распознавание речи, компьютерная лингвистика и обработка естественных языков, медицинская диагностика, финансовые приложения, интеллектуальные игры и многих других.

Что касается медицинской диагностики, то по набору определенных характеристик пациента (симптомов) требуется определить, какое у больного заболевание (и болен ли он вообще).

Объектами являются пациенты, их признаковым описанием — набор характеристик, а выходом — номер класса. Обучение проходит на достаточном объеме прецедентов. Таким образом, получаем задачу классификации [9].

## II. МЕТОДЫ И ИНСТРУМЕНТЫ

Как было сказано выше, задача диагностики заболеваний относится к одной из задач, решаемых при помощи машинного обучения. Для решения этой задачи лучше всего подходит такой тип настройки системы, как «обучение с учителем». В данном исследовании использовалась база записей звуков легких, которые содержат набор определенных параметров, являющиеся входом системы. На выходе системы имеется некий результат — отклик, характеризующий состояние человека (здоров или болен). Между параметрами и откликом имеются определенные зависимости, которые необходимо установить. Для этого используются так называемые прецеденты, то есть такие наборы параметров, для которых известен конечный отклик. Такие прецеденты называются обучающей выборкой. На основе их обучается алгоритм классификации.

В данном исследовании рассматривались и использовались линейные классификаторы (метод опорных векторов, логистическая регрессия), наивный байесовский классификатор, дерево решений (CART алгоритм) и метод *k* ближайших соседей.

### A. Метод опорных векторов

Метод опорных векторов (Support Vector Machine) относится к группе линейных классификаторов. Цель метода — найти плоскость (в случае с многоклассовой классификацией — гиперплоскость), которая разделяет множества объектов. Разделяющей гиперплоскостью будет гиперплоскость, максимизирующая расстояние до двух параллельных гиперплоскостей. Алгоритм работает в предположении, что чем больше разница или расстояние между этими параллельными гиперплоскостями, тем меньше будет средняя ошибка классификатора.

Метод опорных векторов неустойчив по отношению к шуму в исходных данных и стандартизации данных. Если обучающая выборка содержит шумовые выбросы, этот метод использовать нецелесообразно [10], [11].

Преимущества метода: это наиболее быстрый метод нахождения решающих функций. Он сводится к решению задачи квадратичного программирования в выпуклой области, которая всегда имеет единственное решение. Метод находит разделяющую полосу максимальной ширины, что позволяет в дальнейшем осуществлять более уверенную классификацию.

### B. Логистическая регрессия

Основная идея логистической регрессии, как и метода опорных векторов, заключается в том, что пространство исходных значений может быть разделено линейной границей (т.е. прямой (в случае трех — плоскость, и так далее)) на две соответствующих класса области.

Если задана обучающая выборка пар «объект, ответ»:

$$X^m = \{(x_1, y_1), \dots, (x_m, y_m)\}, \quad (1)$$

где  $X \in R^n$  — пространство признаков описаний объектов,  $Y$  — конечное множество номеров (имён, меток) классов, то задача обучения линейного классификатора заключается в том, чтобы по выборке  $X^m$  настроить вектор весов  $\omega$ . В логистической регрессии для этого решается задача минимизации эмпирического риска с функцией потерь специального вида.

После того, как решение  $\omega$  найдено, становится возможным не только вычислять классификацию для произвольного объекта  $x$ , но и оценивать апостериорные вероятности его принадлежности классам:

$$P\{y | x\} = \sigma(y \langle x, \omega \rangle), y \in Y,$$

где  $\sigma(z) = \frac{1}{1 + e^{-z}}$  — сигмоидная функция. Во многих приложениях апостериорные вероятности необходимы для оценивания рисков, связанных с возможными ошибками классификации [10], [12].

Возможность оценивать апостериорные вероятности и риски является преимуществом данного метода.

К его недостаткам следует отнести то, что оценки вероятностей и рисков могут оказаться неадекватными, поскольку метод предполагает, что плотности вероятностей будут одинаковыми.

### С. Байесовский классификатор

Байесовский классификатор (Bayes) основан на принципе максимума апостериорной вероятности. Для классифицируемого объекта вычисляются функции правдоподобия каждого из классов, по ним вычисляются апостериорные вероятности классов. Объект относится к тому классу, для которого апостериорная вероятность максимальна.

Т. е. если  $X \ni x = (\xi_1, \dots, \xi_n)$  — объекты, а  $Y$  — классы, то классификатор должен отображать объекты в классы с минимальной вероятностью ошибки:

$$a(x) : X \rightarrow Y.$$

Байесовский классификатор основывается на принципе максимума апостериорной вероятности:

$$a(x) = \arg \max_{y \in Y} P(y | x),$$

где  $P(y | x)$  — вероятность события  $x$  принадлежит классу  $y$ .

Наивный байесовский классификатор (naive Bayes classifier) — специальный частный случай байесовского классификатора, основанный на дополнительном предположении, что все признаки  $\{\xi_i\}$  объекта независимы друг от друга.

Предположение о независимости существенно упрощает задачу, так как оценить  $n$  одномерных плотностей гораздо легче, чем одну  $n$ -мерную плотность. К сожалению, оно крайне редко выполняется на практике, отсюда и название метода [10]. Поэтому к недостаткам метода относится все-таки предполагаемая независимость функций.

К преимуществам байесовского классификатора следует отнести отсутствие чувствительности к посторонним функциям, квадратическую границу решений, а также то, что это относительно быстрый алгоритм.

### Д. Метод ближайших соседей

Метод ближайших соседей (англ.  $k$ -nearest neighbors algorithm,  $k$ -NN) — простейший метрический классификатор, основанный на оценивании сходства объектов. Классифицируемый объект относится к тому классу, которому принадлежат ближайшие к нему объекты обучающей выборки.

Если обучающая выборка задана как (1) и на множестве объектов задана функция расстояния  $\rho(x, x')$ , то эта функция должна быть достаточно адекватной моделью сходства объектов. Чем больше значение этой функции, тем менее схожими являются два объекта  $x, x'$ .

В наиболее общем виде алгоритм ближайших соседей есть:

$$a(x) = \arg \max_{y \in Y} \sum_{i=1}^m [x_{i,u} = y] \omega(i, u),$$

где через  $x_{i,u}$  обозначается тот объект обучающей выборки, который является  $i$ -м соседом произвольного объекта  $u$ ,  $\omega(i, u)$  — заданная весовая функция, которая оценивает степень важности  $i$ -го соседа для классификации объекта  $u$ . Естественно полагать, что эта функция неотрицательна и не возрастает по  $i$ .

По-разному задавая весовую функцию, можно получать различные варианты метода ближайших соседей [9], [11], [13].

Такой алгоритм просто реализовать, однако точность классификации сильно зависит от задачи и вычислительная трудоемкость достаточно высока.

### Е. Дерево принятия решений

Дерево принятия решений (также может называться деревом классификации или регрессионным деревом) — средство поддержки принятия решений, используемое в статистике и анализе данных для прогнозных моделей. Структура дерева представляет собой «листья» и «ветки». На ребрах («ветках») дерева решения записаны атрибуты, от которых зависит целевая функция, в «листьях» записаны значения целевой функции, а в остальных узлах — атрибуты, по которым различаются случаи. Чтобы классифицировать новый случай, надо спуститься по дереву до листа и выдать соответствующее значение. Цель состоит в том, чтобы создать модель, которая предсказывает значение целевой переменной на основе нескольких переменных на входе.

Алгоритм CART (Classification and Regression Tree) решает задачи классификации и регрессии построением дерева решений.

Алгоритм CART (Classification and Regression Tree) предназначен для построения бинарного дерева решений. Бинарные деревья также называют двоичными; это значит, что каждый узел дерева при разбиении имеет только двух потомков. Для алгоритма CART «поведение» объектов выделенной группы означает долю модального значения выходного признака. Выделенные группы — те, для которых эта доля достаточно высока. На каждом шаге построения дерева правило, формируемое в узле, делит заданное множество примеров на две части — часть, в которой выполняется правило (потомок — right) и часть, в которой правило не выполняется (потомок — left).

Преимуществом алгоритма CART является определенная гарантия того, что если искомые детерминации существуют в исследуемой совокупности, то они будут выявлены. Кроме того, CART позволяет не «замыкаться» на единственном значении выходного признака, а искать все такие его значения, для которых можно найти соответствующее объясняющее выражение [10].

Данный метод прост в понимании и интерпретации, не требует подготовки данных, кроме того позволяет оценить модель при помощи статистических тестов. Это дает возможность оценить надежность модели.

Однако к недостаткам алгоритма CART следует отнести тот факт, что существуют концепты, которые сложно понять из модели, так как модель описывает их сложным путём. В этом случае имеют дело с непомерно большими деревьями. Кроме того, с разрастанием дерева необходимо переобучение модели.

#### F. Критерии оценки методов

В данном исследовании использовались следующие критерии оценки методов классификации [14], [15]:

- Точность

Точность показывает, какую долю объектов, распознанных, как объекты положительного класса, мы предсказали верно. На примере: точность — это сколько из отмеченных нами больных людей реально больные.

$$P = TP / (TP + FP), \quad (2)$$

где TP – истинно положительные ответы, FP – ложно положительные ответы.

- Полнота

Полнота показывает, какую долю объектов, реально относящихся к положительному классу, мы предсказали верно. На примере: полнота — это сколько из всех больных мы смогли отметить:

$$R = TP / (TP + FN), \quad (3)$$

где TP – истинно положительные ответы, FN – ложно отрицательные ответы.

- F-мера

Точность и полнота хорошо оценивают качество классификатора для задач со смещенной априорной вероятностью, но если мы обучили модель с высокой точностью, то может случиться так, что полнота у такого классификатора низкая, и наоборот. Чтобы связать точность с полнотой, вводят F-меру как среднее гармоническое точности и полноты.

$$F = 2 \cdot \frac{P \cdot R}{P + R}. \quad (4)$$

### III. РЕЗУЛЬТАТЫ

В предыдущих работах авторов [16], [17] были приведены исследования для выявления диагностических признаков по параметрам, получаемым на основе аппарата статистик высших порядков.

Как было показано, с точки зрения важности диагностических признаков показательными являются параметры, получаемые из функции бикогерентности сигналов звуков дыхания, такие как: ее максимальное значение и соответствующее ему значение нормированной бичастоты. Кроме того, поскольку авторами была разработана методика разбиения сигналов на дыхательные фазы, появилась возможность получать различные параметры звуков как в каждой фазе отдельно, так и интегральные оценки по всему сигналу [17].

В работе [18] авторами был применен метод машинного обучения для некоторых рассчитанных параметров. По сравнению с предыдущей работой в данном исследовании использовалась расширенная база звуков легких с более точными диагнозами. В ходе дальнейшей работы количество параметров, получаемых с одного звукового сигнала, было увеличено до 20. А потому возникла необходимость, во-первых, выбрать из них наиболее значимые для постановки диагноза, а во-вторых, подобрать такой классификатор, который давал бы наилучшие результаты с точки зрения точности.

Для настройки классификаторов использовалась база из 134 пациентов (54 здоровых и 80 больных бронхо-легочными заболеваниями).

Компьютерная регистрация и первичная обработка звуковой информации, записанной с поверхности грудной клетки пациентов, была проведена с помощью четырехканального фоноспирографического компьютерного комплекса "КоРА-03М". Звуки легких, образующиеся в бронхо-легочной системе человека, регистрировались синхронно с помощью четырех оригинальных миниатюрных высокочувствительных акселерометров, которые крепились на разных точках поверхности грудной клетки, определяемых врачом. Комплекс регистрирует и записывает звуки в wav-формате, что позволяет обрабатывать, анализировать, а при необходимости и передавать сигналы.

Состояния бронхо-легочной системы пациентов были верифицированы ранее с помощью стандартных клинических методов функциональной диагностики.

В ходе исследования было определено, что наилучшие результаты с точки зрения точности были получены при использовании семи параметров звуков дыхания:

- cycle\_c3\_mean – среднее по четырем каналам значение коэффициента асимметрии для каждого дыхательного цикла;
- cycle\_c3\_std – среднееквадратическое значение коэффициента асимметрии для каждого цикла;





- $cycle\_w\_mean$  – средняя по четырем каналам частота, соответствующая максимальному значению функции бикогерентности в каждом дыхательном цикле;
- $cycle\_w\_std$  – среднееквадратическое значение данной частоты;
- $f_{max}$  – частота, соответствующая максимуму функции бикогерентности сигнала, не разбитого на дыхательные циклы в каждом канале;
- $f_{mean}$  – средняя частота по всем каналам;
- $v_{max}$  – максимальное значение функции бикогерентности каждого канала.

Различные классы были получены путем разделения класса «болен» на отдельные подклассы. В итоге получилось 4 класса:

- Класс 1: Здоров
- Класс 2: ХОБЛ, прикорневой нижнедолевой пневмофиброз
- Класс 3: ХОБЛ, диффузионный пневмофиброз
- Класс 4: Другая патология

Общая база из 134 пациентов была разбита на обучающую и тестовую выборки в соотношении 85% и 15%. После обучения классификатора с его помощью классифицировалась тестовая выборка. Использовался метод перекрестной проверки — метод формирования обучающего и тестового множеств для обучения аналитической модели в условиях недостаточности исходных данных или неравномерного представления классов. Для успешного обучения аналитической модели необходимо, чтобы классы были представлены в обучающем множестве примерно в одинаковой пропорции. Однако, если данных недостаточно, как в данном случае, один из классов может оказаться доминирующим. Это может вызвать «перекос» в процессе обучения, и доминирующий класс будет рассматриваться как наиболее вероятный. Метод перекрестной проверки позволяет избежать этого.

В его основе лежит разделение исходного множества данных на  $k$  примерно равных блоков (в нашем случае бралось  $k = 7$ ). Затем на  $k - 1$ , т.е. на 6-ти блоках производилось обучение модели, а 7-й блок использовался для тестирования. Процедура повторялась  $k$  раз, при этом на каждом проходе для проверки выбирался новый блок, а обучение производилось на оставшихся.

Перекрестная проверка имеет два основных преимущества перед применением одного множества для обучения и одного для тестирования модели. Распределение классов оказывается более равномерным, что улучшает качество обучения.

Результаты работы различных классификаторов представлены в таблицах 1-5. Приведенные значения точности, полноты и  $F$ -меры считались соответственно по формулам (2)-(4).

Итоговое значение рассчитывалось как среднее значение по всем четырем классам.

ТАБЛИЦА 1 КЛАССИФИКАЦИЯ МЕТОДОМ ОПОРНЫХ ВЕКТОРОВ

Диагноз	Точность	Полнота	F-мера
Класс 1	100%	85%	92%
Класс 2	100%	80%	89%
Класс 3	86%	100%	82%
Класс 4	92%	100%	95%
Итоговое значение	95%	91%	90%

ТАБЛИЦА 2 КЛАССИФИКАЦИЯ МЕТОДОМ ЛОГИЧЕСКОЙ РЕГРЕССИИ

Диагноз	Точность	Полнота	F-мера
Класс 1	50%	25%	33%
Класс 2	55%	60%	57%
Класс 3	50%	100%	66%
Класс 4	57%	75%	64%
Итоговое значение	53%	55%	54%

ТАБЛИЦА 3 КЛАССИФИКАЦИЯ С ПОМОЩЬЮ НАИВНОГО БАЙЕСОВСКОГО КЛАССИФИКАТОРА

Диагноз	Точность	Полнота	F-мера
Класс 1	100%	13%	23%
Класс 2	100%	60%	75%
Класс 3	50%	66%	56%
Класс 4	33%	50%	39%
Итоговое значение	79%	40%	53%

ТАБЛИЦА 4 КЛАССИФИКАЦИЯ МЕТОДОМ К-БЛИЖАЙШИХ СОСЕДЕЙ

Диагноз	Точность	Полнота	F-мера
Класс 1	85%	75%	80%
Класс 2	83%	100%	90%
Класс 3	100%	66%	79%
Класс 4	66%	75%	70%
Итоговое значение	84%	80%	82%

ТАБЛИЦА 5 КЛАССИФИКАЦИЯ С ПОМОЩЬЮ ДЕРЕВА ПРИНЯТИЯ РЕШЕНИЙ

Диагноз	Точность	Полнота	F-мера
Класс 1	88%	100%	94%
Класс 2	100%	80%	90%
Класс 3	100%	100%	100%
Класс 4	82%	87%	84%
Итоговое значение	93%	92%	92%



Как видно по данным, приведенным в таблицах, наилучшие результаты показали классификаторы, обученные на основе метода опорных векторов и дерева принятия решений, с соответствующими показателями точности 95% и 93% соответственно.

Таким образом, предложенная методика классификации звуков легких на основе найденных параметров может служить вспомогательным инструментом для работы врача-пульмонолога.

#### Выводы

В работе были исследованы и проанализированы классификаторы разных типов для выявления заболеваний легких. А именно, классификатор на основе метода ближайших соседей, на основе метода опорных векторов, на основе наивного Байесовского классификатора, метода дерева решений и метода логистической регрессии.

Также разработаны алгоритмы реализации классификаторов базы звуков дыхания. Для базы звуков лёгких оптимальным оказался классификатор, обученный с помощью метода опорных векторов и классификатор, обученный с помощью дерева принятия решений. Они показали наибольшую точность принятия правильных решений.

Полученные модели классификаторов могут быть легко адаптированы для большего количества параметров. Его точность будет увеличиваться с увеличением начальной базы данных.

В дальнейших исследованиях будет поставлена задача дальнейшего подбора наиболее значимых параметров сигналов звуков дыхания и усовершенствования классификаторов для возможности более тонкой классификации большего числа различных патологий бронхо-легочной системы.

#### ПЕРЕЧЕНЬ ССЫЛОК

- [1] T. Kaur and E. N. Gupta, "Classification of Lung Diseases Using Optimization Techniques," *Int. J. Sci. Res. Dev.*, vol. 3, no. 8, pp. 852–854, Nov. 2015.  
**URL:** <http://ijsrd.com/Article.php?manuscript=IJSRDV3I80412>
- [2] "Vsemirnaja organizacija zdravoohraneniya. 10 vedysih smertej v mire [World Health Organization. 10 leading deaths in the world.]," *WHO*, 2017. [Online]. Available: <http://www.who.int/mediacentre/factsheets/fs310/ru/>.
- [3] A. A. Grinchenko, V. T. Makarenkov, A. P. Makarenkova, "Kompjuternaya auskultaciya — novij metod objektivizacii harakteristik zvykov dihaniya [Computer auscultation is a new method of objectifying the lung sounds characteristics]," *Klin. Inform. i teleditsina*, vol. 6, no. 7, pp. 31–36, 2010.
- [4] A. Jones, "A Brief Overview of the Analysis of Lung Sounds," *Physiotherapy*, vol. 81, no. 1, pp. 37–42, Jan. 1995.  
**DOI:** [10.1016/S0031-9406\(05\)67034-4](https://doi.org/10.1016/S0031-9406(05)67034-4)
- [5] R. L. H. Murphy *et al.*, "Automated lung sound analysis in patients with pneumonia," *Respir. Care*, vol. 49, no. 12, pp. 1490–7, Dec. 2004. **PMID:** [15571639](https://pubmed.ncbi.nlm.nih.gov/15571639/)
- [6] D. Emmanouilidou, K. Patil, J. West, and M. Elhilali, "A multiresolution analysis for detection of abnormal lung sounds," in *2012 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 2012, pp. 3139–3142. **DOI:** [10.1109/EMBC.2012.6346630](https://doi.org/10.1109/EMBC.2012.6346630)
- [7] S. Ulukaya, G. Serbes, I. Sen, and Y. P. Kahya, "A lung sound classification system based on the rational dilation wavelet transform," in *2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 2016, pp. 3745–3748. **DOI:** [10.1109/EMBC.2016.7591542](https://doi.org/10.1109/EMBC.2016.7591542)
- [8] E. Shams, D. Karimi, and Z. Moussavi, "Bispectral analysis of tracheal breath sounds for Obstructive Sleep Apnea," in *2012 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 2012, pp. 37–40.  
**DOI:** [10.1109/EMBC.2012.6345865](https://doi.org/10.1109/EMBC.2012.6345865)
- [9] "Mashinnoe obychie [Machine Learning]." [Online]. Available: [http://www.machinelearning.ru/wiki/index.php?title=Machine\\_Learning](http://www.machinelearning.ru/wiki/index.php?title=Machine_Learning).
- [10] T. Hastie, R. Tibshirani, and J. H. Friedman, *The elements of statistical learning: data mining, inference, and prediction*, Second. New York, NY, USA: Springer, 2009.  
**ISBN:** [978-0387848570](https://www.isbn-international.org/product/978-038784857-0)
- [11] V. N. Vapnik, *Vosstanovlenie zavisimostej po empiricheskim dannim [Recovery of dependencies according to empirical data]*. Moscow, USSR: Nauka, 1979.
- [12] S. A. Ajvazyan, V. M. Byhshtaber, I. S. Jenyukov, and L. D. Meshalkin, *Prikladnaya statistika: klassifikaciya i snizheniye razmernosti [Applied statistics: classification and dimension reduction]*. Moscow, USSR: Finansi a statistika, 1989.
- [13] U. I. Zhyravlev, V. V. Ryazanov, and O. V. Senko, *Raspoznavaniye. Matematicheskie metody. Programmnaya sistema. Prakticheskie primeneniya [Recognition. Mathematical methods. Practical applications]*. Moscow, Russia: Fazis, 2006. **ISBN:** [5-7036-0108-8](https://www.isbn-international.org/product/5-7036-0108-8)
- [14] D. M. W. Powers, "Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness & Correlation," *J. Mach. Learn. Technol.*, vol. 2, no. 1, pp. 37–63, 2011. **URL:** <https://www.bioinfopublication.org/viewhtml.php?artid=BI40001114>
- [15] T. Fawcett, "An introduction to ROC analysis," *Pattern Recognit. Lett.*, vol. 27, no. 8, pp. 861–874, Jun. 2006.  
**DOI:** [10.1016/j.patrec.2005.10.010](https://doi.org/10.1016/j.patrec.2005.10.010)
- [16] A. S. Poreva, A. A. Makarenkova, Y. S. Karplyuk, and A. A. Goncharenko, "Primeneniye polispectral'nogo analiza dlya opredeleniya diagnosticheskikh priznakov v zvykah dihaniya bol'nih HOBL [The using of polyspectral analysis for determining diagnostic signs in the lung sounds in COPD patients]," *Visn. Nac. Teh. Univ. "KhPI"*, no. 36, pp. 49–55, 2014.  
**URI:** <http://repository.kpi.kharkov.ua/handle/KhPI-Press/9386>
- [17] A. Poreva, Y. Karplyuk, A. Makarenkova, and A. Makarenkov, "Detection of COPD's diagnostic signs based on polyspectral lung sounds analysis of respiratory phases," in *2015 IEEE 35th International Conference on Electronics and Nanotechnology (ELNANO)*, 2015, pp. 351–355.  
**DOI:** [10.1109/ELNANO.2015.7146908](https://doi.org/10.1109/ELNANO.2015.7146908)
- [18] H. S. Porieva and D. Honcharova, "Doslidzhennia roboty klasyfikatoriv dlia optymizatsii postanovky diahnoziv bronkholehenevykh zakhvoriuvan [Research of classifiers' work to optimize diagnoses bronchopulmonary diseases]," *Electron. Commun.*, vol. 21, no. 4, pp. 44–48, Nov. 2016.  
**DOI:** [10.20535/2312-1807.2016.21.4.81930](https://doi.org/10.20535/2312-1807.2016.21.4.81930)

Надійшла до редакції 15 серпня 2017 р.



УДК 004.9

# Методи машинного навчання для дослідження сигналів звуків легенів

Порєва Г.С., ORCID [0000-0002-3797-025X](https://orcid.org/0000-0002-3797-025X)e-mail [porevanna@gmail.com](mailto:porevanna@gmail.com)Вайтишин В.І., ORCID [0000-0002-8617-9042](https://orcid.org/0000-0002-8617-9042)e-mail [valenook.ua@gmail.com](mailto:valenook.ua@gmail.com)Карплюк Є.С., к.т.н., ORCID [0000-0002-4224-7760](https://orcid.org/0000-0002-4224-7760)e-mail [yevgeniy@karplyuk.kiev.ua](mailto:yevgeniy@karplyuk.kiev.ua)

Кафедра електронної інженерії, Факультет Електроніки,  
Національний технічний університет України  
"Київський політехнічний інститут імені Ігоря Сікорського" [kpi.ua](http://kpi.ua)  
Київ, Україна

**Реферат**—В статті розглянуто основні методи машинного навчання з метою застосування їх до задачі класифікації звуків легень. На основі бази звуків легень було отримано ряд параметрів сигналів. Завданням дослідження було провести класифікацію звуків за допомогою п'яти різних методів машинного навчання, а також визначити з ряду параметрів сигналів ті, які дають в кінцевому рахунку найвищу точність. Таким чином було знайдено сім найбільш діагностично цінних властивостей звуків дихання та виявлено, що два методи машинного навчання — метод опорних векторів і метод дерева прийняття рішень — показали найкращі результати. Таким чином, дана методика класифікації може служити як допоміжний інструмент для лікаря-пульмонолога в постановці діагнозу.

Бібл. 18, табл. 5.

*Ключові слова* — звуки легень; машинне навчання; класифікатор; метод опорних векторів; метод дерева прийняття рішень.

UDC 004.9

# Machine learning methods for the study of the lungsounds signals

A. S. Poreva, ORCID [0000-0002-3797-025X](https://orcid.org/0000-0002-3797-025X)e-mail [porevanna@gmail.com](mailto:porevanna@gmail.com)V. I. Vaityshyn, ORCID [0000-0002-8617-9042](https://orcid.org/0000-0002-8617-9042)e-mail [valenook.ua@gmail.com](mailto:valenook.ua@gmail.com)Ye. S. Karplyuk, PhD, ORCID [0000-0002-4224-7760](https://orcid.org/0000-0002-4224-7760)e-mail [yevgeniy@karplyuk.kiev.ua](mailto:yevgeniy@karplyuk.kiev.ua)

Electronic Engineering Department, Faculty of Electronics,  
National Technical University of Ukraine "Igor Sikorsky Kiev Polytechnic Institute" [kpi.ua](http://kpi.ua)  
Kyiv, Ukraine

**Abstract**—The article considers the basic methods of machine learning for applying them to the task of the lungs sounds classifying. A number of signal parameters were obtained on the basis of the lungs sounds set. The task of the study was to classify sounds using five different machine learning methods. It was also necessary to determine from a number of signal parameters those that give the highest accuracy. Thus the seven most diagnostically valuable parameters of lung sounds were found. The results showed that two methods of machine learning — the method of reference vectors and the decision tree method — have the best accuracy. Thus this classification technique can serve as an auxiliary tool for a pulmonary physician to diagnosis.

Ref. 18, tabl. 5.

*Keywords* — lung sounds; machine learning; classifier; support vector method; decision tree method.

