УДК 621.39
DOI: 10.25686/978-5-8158-2474-4-2025-13-21

Метод обнаружения принимаемых мод сигнала на изображении ионограммы радиозондирования ионосферы с использованием машинного обучения

В. А. Иванов, Н. А. Конкин, В. В. Овчинников, М. И. Рябова
Поволжский государственный технологический университет, Йошкар-Ола, Россия

Аннотация. В статье представлен комплексный метод автоматической обработки изображений ионограмм, полученных в результате наклонного зондирования ионосферы, с целью выявления полезных сигналов на фоне флуктуационных и сосредоточенных помех. Предлагаемый метод сочетает классические подходы к фильтрации (обеляющее и медианное эквалайзирование) с методами машинного обучения на основе кластерного анализа. Основным компонентом является алгоритм машинного обучения на основе кластеризации k-means, применяемый к изображению ионограммы, преобразованному в формат цветового пространства RGB, для автоматического выделения мод сигнала. Предварительная фильтрация обеспечивает стандартизацию распределения интенсивности сигнала и снижение влияния шумов, что позволяет повысить точность сегментации. В серии натурных экспериментов, проведённых на радиотрассе Кипр – Йошкар-Ола, показано, что оптимальное число кластеров (11) обеспечивает наилучшее разделение компонент ионограммы по уровню сигнал/шум. Разработанный метод может быть использован в составе когнитивных радиосистем для автоматического анализа и выбора рабочих частот радиоканалов в условиях динамично изменяющейся среды.

***Ключевые слова*:** ионограмма, зашумленное изображение, фильтрация помех, кластеризация, k-means, машинное обучение, автоматическое обнаружение сигнала, КВ-связь, когнитивные системы.

Echo Signal detection on ionograms of ionospheric sounding with the use of machine learning methods

V. A. Ivanov, N. A. Konkin, V. V. Ovchinnikov, M. I. Ryabova
Volga State University of Technology, Yoshkar-Ola, Russia

Abstract. This paper presents a comprehensive method for the automatic processing of ionogram images obtained through oblique ionospheric sounding, aimed at identifying echo signals amid both fluctuating and narrowband interference. The proposed approach combines classical filtering techniques–specifically whitening and median equalization–with machine learning methods based on cluster analysis. The core component of the method is the k-means clustering algorithm, which is applied to the ionogram image converted into the RGB color space to automatically extract signal modes. The preliminary filtering stage standardizes the signal intensity distribution and reduces noise influence, thereby improving segmentation accuracy. A series of field experiments conducted along the Cyprus–Yoshkar-Ola radio path demonstrated that using 11 clusters yields the most effective separation of ionogram components based on their signal-to-noise ratio. The developed method can be integrated into cognitive radio systems for automatic analysis and selection of operational frequency bands in highly dynamic propagation environments.

Keywords: ionogram, noisy image, interference filtering, clustering, k-means, machine learning, automatic signal detection, HF communication, cognitive systems.

Введение

Методы машинного обучения для обработки изображений нашли широкое применение в различных областях техники [1]. Важным направлением в научных исследованиях является обработка изображений с целью дальнейшего получения информации об изучаемом объекте [2]. В частности, к этому направлению относится и задача извлечения информации о параметрах многомерного ионосферного канала ВЧ-связи из изображений ионограмм, получаемых в результате зондирования ионосферы. Ионограммы, полученные при помощи вертикального и наклонного зондирования ионосферы, являются ключевыми источниками информации о многомерной структуре среды распространения. Однако их практическое использование осложняется наличием шумов, вызванных как природными, так и антропогенными источниками, а также высокой изменчивостью ионосферных условий. При этом полезные сигналы и сигналы помех являются стохастическими процессами. В условиях когнитивных радиосистем и автономных радиосенсоров возникает необходимость автоматического анализа ионограмм для выделения частотных каналов с наилучшим отношением сигнал/шум. В этой задаче на первом этапе требуется получить изображение ионограммы, очищенное от помех. В таком случае оставшееся изображение может применяться для дальнейшего анализа при помощи машинного обучения с целью выделения полезного сигнала. Такая очистка позволит

определять в автоматическом режиме необходимые для пользователей параметры канала ВЧ-связи, а также осуществлять автоматизированную обработку большого количества ионограмм.

Вопросам очистки ионограмм посвящено достаточно много работ различных авторов [3, 4]. В настоящем исследовании предлагается комплексный метод, сочетающий классические фильтрационные подходы (обеляющее и медианное эквалайзирование) с машинным обучением, в частности алгоритмом кластеризации k-means [5], для автоматического выделения полезного сигнала на ионограммах. В отличие от нейросетевых решений [6], требующих длительного обучения и больших объёмов размеченных данных, используемый подход обеспечивает быструю и интерпретируемую сегментацию, адаптируемую к конкретным условиям помех. Новым будет является разработка комплексного метода с применением алгоритма машинного обучения, который можно реализовать в автоматическом режиме. Он предназначен для определения по результатам интеллектуальной обработки ионограмм частотной зависимости отношения сигнал-шум для всего множества каналов ВЧ-диапазона и является актуальным для выбора оптимального из них.

Постановка задачи

В КВ-диапазоне имеют место изменчивые флуктуационные и сосредоточенные помехи. Последние обусловлены работой посторонних систем КВ-связи. Полосы частот сосредоточенных помех обычно составляют 3 кГц или кратны этой величине. Время стационарности вариаций в основном не меньше 10 с.

Спектр комплексной амплитуды принимаемой смеси сигнала и помех можно записать в виде следующей суммы:

$$Y_R(j\omega) = U_R(j\omega) + \sum_{k=1}^{k_0} N_k(j\omega) + N_0(j\omega),$$

где $U_R(j\omega)$ – спектр зондирующего сигнала; $N_k(j\omega)$ – спектр отдельной сосредоточенной помехи; $N_0(j\omega)$ – спектр флуктуационной помехи.

Спектр мощности сигнала разностной частоты Ω можно представить в виде:

$$S_\tau^2(\Omega = \tau \cdot \dot{\omega}) = S^2(\Omega = \tau \cdot \dot{\omega}) + \sum_{k=1}^{k_0} N_k^2(\Omega) + N_0^2(\Omega).$$

Видно, что шум присутствует как на задержках принимаемого сигнала, так и на остальных задержках из области априорной неопределенности. Решение задачи автоматического выделения в матрице–ионограмме $S_\tau^2(\Omega = \tau \cdot \dot{\omega})$ отсчетов зондирующего сигнала требует применения эффективных методов фильтрации отсчетов помех и машинного обучения для обнаружения сигнала на фоне оставшегося при фильтрации шума. Для фильтрации помех необходимо последовательно применять ряд адаптивных алгоритмов, таких как обеляющее и медианное эквалайзирование. Их рассмотрение для решения поставленной задачи представлено в работах [4, 7, 8].

Целью настоящей работы является разработка и экспериментальная проверка метода автоматического обнаружения мод принимаемого сигнала на ионограммах наклонного зондирования ионосферы в условиях флуктуационных и сосредоточенных помех. Метод должен обеспечивать: подавление помех и шумов за счёт предварительной адаптивной обработки ВЧ-сигнала до его сжатия; нормализацию распределения амплитудных отсчётов для повышения устойчивости алгоритма обработки; автоматическую сегментацию ионограммы с применением алгоритма машинного обучения для выделения кластеров с различным отношением сигнал/шум.

Задача формализуется как поэтапная обработка с предварительным обеляющим эквалайзированием широкополосного принимаемого сигнала на этапе его спектрального представления и последующая обработка матрицы амплитудных отсчётов с целью выделения кластеров, характеризующихся заданными уровнями отношения сигнал/шум.

Теория

Для исследования и анализа методов фильтрации помех и получения подготовленных изображений ионограмм для обучения алгоритма выделения полезного сигнала нами будут рассматриваться вариационные ряды для величины

$$G(m,n) = 10\lg\frac{S_\tau^2(m,n)}{Me(S_\tau^2)_n} = 10\lg\hat{S}_\tau^2(m,n), \quad (1)$$

где m – номер строки матрицы-ионограммы, соответствующий задержке; n – номер столбца этой матрицы, соответствующий средней частоте парциального канала; $Me(S_\tau^2)_n$ – медиана отсчетов $S_\tau^2(m,n)$ для столбца.

Формула (1) инициирует вторую матрицу того же размера, но с элементами $G(m,n)$. Наши исследования показывают, что действие этих алгоритмов целесообразно проанализировать на основе характеристик вариационных рядов, для которых вариантами являются как отсчеты $S_\tau^2(m,n)$, так и $G(m,n)$. Для обеих функций частоты (номер варианты в ряду, отнесенный к объему выборки) определяют вероятность того, что варианты с меньшими значениями не превысят его, а разность между единицей и этой частотой – вероятность того, что имеются варианты с большими чем в данном отсчете значениями. Поэтому вариационный ряд можно рассматривать как функцию, обратную функции распределения вероятности вариантов.

Обеление осуществляется до операции сжатия сигнала в приёмнике. На начальном шаге находится текущий спектр мощности принимаемого сигнала $Y_R^2(\omega)$ на заданных с некоторым шагом временных выборок, определяющим разрешение в спектре по частоте. Далее спектр мощности усредняется по выборкам, полученным за время его стационарности, равное 10 с [7]. Усредненный спектр амплитуд $\sqrt{\langle Y_R^2(\omega)\rangle}$ используется для эквалайзирования последующих далее спектров, пока за время стационарности набирается следующая для усреднения выборка. Адаптация заключается в том, что в данном алгоритме учитывается изменение во времени усреднённого спектра обеляемых помех. Имеющая место изменчивость помех приводит к тому, что алгоритм все же пропускает на выход небольшое число сосредоточенных помех с уровнем до 10–15 дБ [7, 8, 9]. На рисунке 1 представлен алгоритм действия обеляющего эквалайзирования.

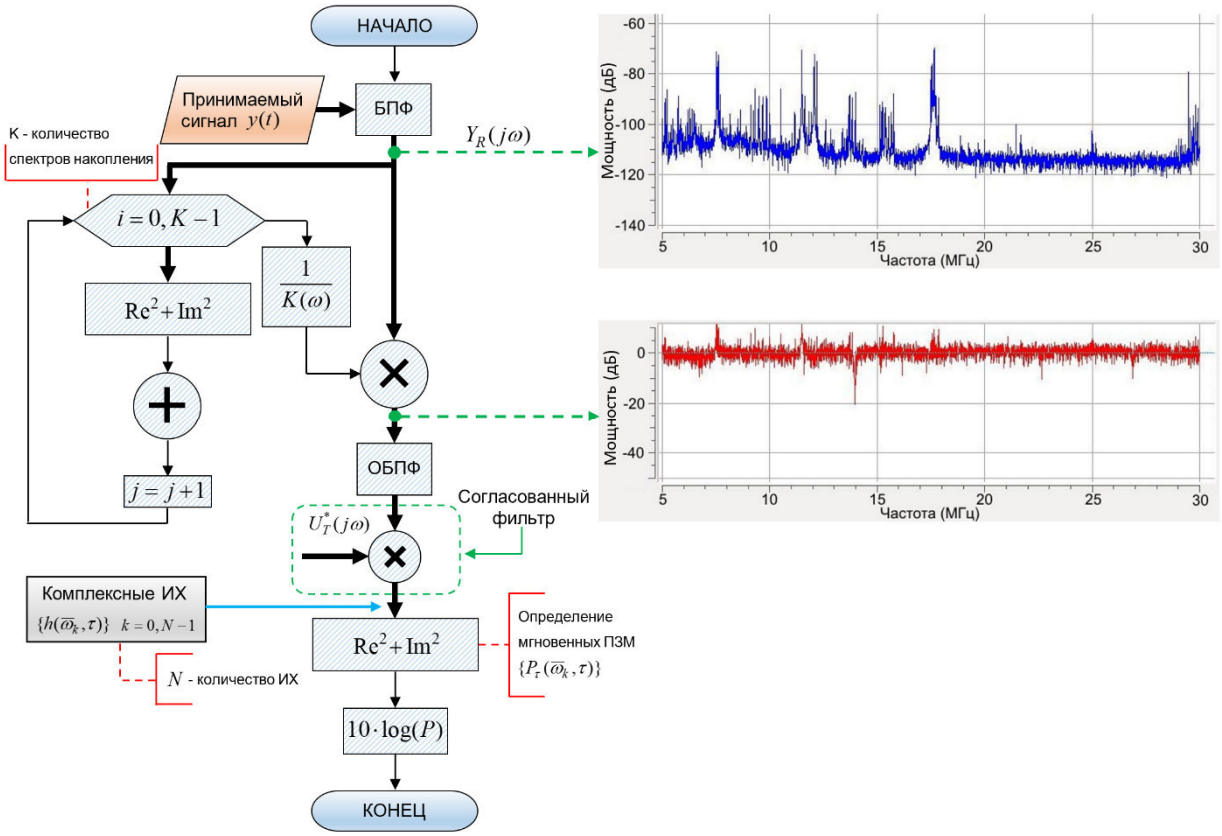

Рис. 1. Алгоритм действия обеляющего эквалайзирования

На рисунке 2 в качестве примера действия алгоритма обеления приведены вариационные ряды для столбцов матрицы с элементами $S_\tau^2(m,n)$ до обеления и после него.

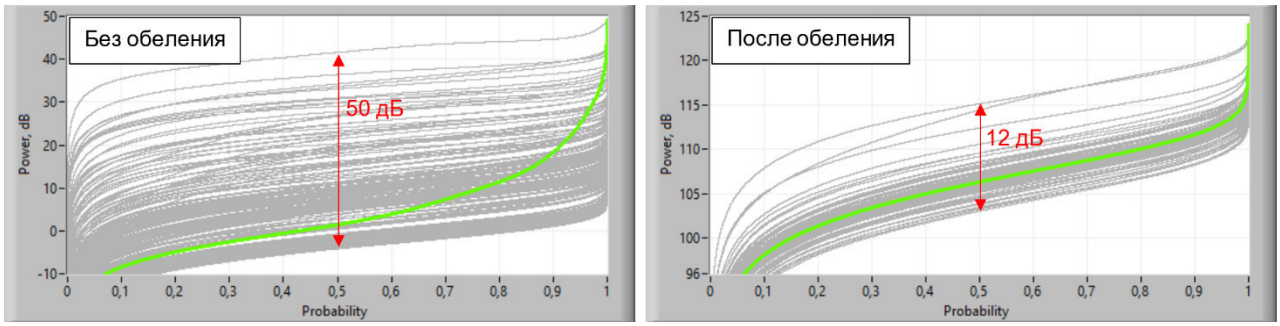

Рис. 2. Вариационные ряды полного множества вектор-столбцов матрицы-ионограммы:
а) без обеления; б) после обеления

В задаче получения ионограммы варианты, принадлежащие сигналу, находятся в малой левой окрестности вероятности, равной 1. Поэтому подавляющее большинство отсчетов варианты соответствует только шуму. Обеление приводит к существенному уменьшению разброса значений варианты шума, который до фильтрации достигал значений 50 дБ, а после нее уменьшился до 12 дБ.

Различия в вариационных рядах связаны с отличием для шумов параметров их функции распределения вероятностей. Обратим внимание на то, что обратная функция к вариационному ряду является по сути законом распределения вероятности. Известно, что для однопараметрического закона путем деления варианты на некоторый параметр можно стандартизировать функцию распределения. Очевидно, что в нашем случае в качестве такого параметра следует выбрать медиану $Me(S_\tau^2)_n$ для вектор-столбца. Вариационный ряд для столбца $(S_\tau^2)_n$ позволяет оценить медиану, которая является характеристикой шума, так как его отсчеты преобладают в элементах столбца. Деление каждого столбца матрицы на его медиану называют медианным эквалайзированием. На рисунке 3 представлен алгоритм действия медианного эквалайзирования, выполняющегося после процедуры обеления.

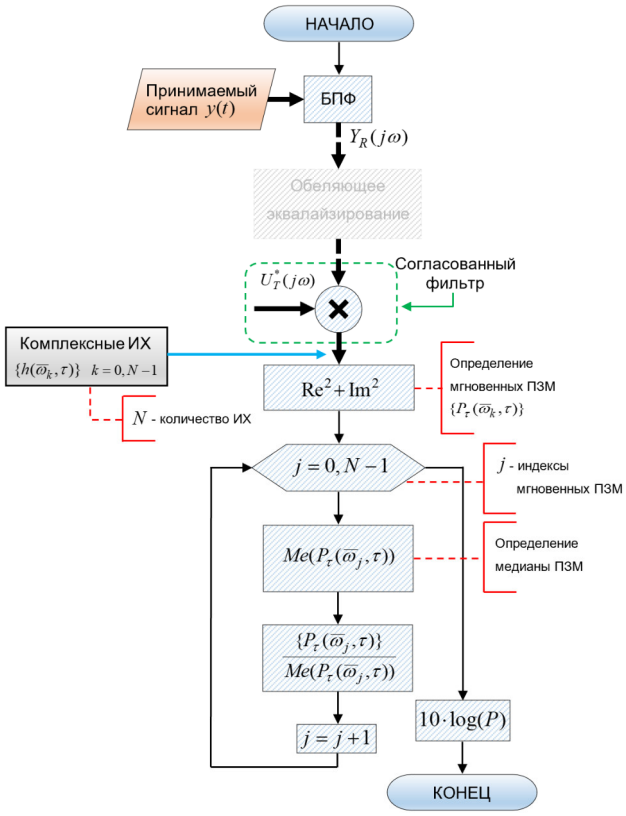

Рис. 3. Алгоритм действия медианного эквалайзирования

Рисунок 4 иллюстрирует действие медианного эквалайзирования в случаях без предварительного обеления и с обелением.

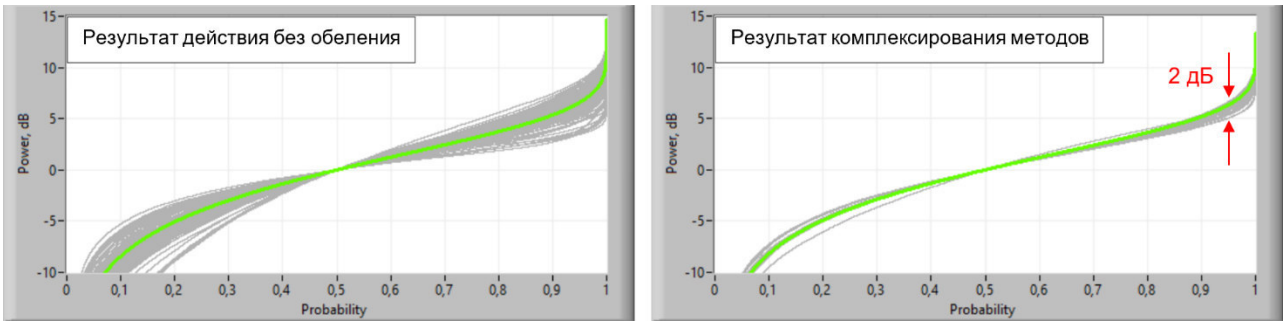

Рис. 4. Вариационные ряды полного множества вектор-столбцов матрицы-ионограммы: без обеления, но с медианным эквалайзированием (*слева*); с обелением и медианным эквалайзированием (*справа*)

Как и следовало ожидать, медианный эквалайзер, особенно при обеляющем эквалайзировании, практически стандартизирует функцию распределения, так как разброс варианты составляет всего 2 дБ (см. рис. 4). В результате такого эквалайзирования середина каждой функции $G(m,n)$ смещается в нуль, в том числе и для вариационного ряда из элементов всей матрицы. Вариационные ряды для такого множества отсчетов изображены на рисунке 4 зеленым цветом. Обратим внимание на то, что в случае применения обеления и медианного эквалайзирования вариацианный ряд для всей матрицы практически совпадает с рядом для столбца с самыми высокими значениями варианты. Этот эффект позволяет применять полученные изображения ионограмм для обучения алгоритма обнаружения полезного сигнала.

На рисунке 5 представлены ионограммы до обработки и после обработки комплексным алгоритмом [10]. Вертикальные прямые являются следствием воздействия на соответствующие каналы мощных сосредоточенных помех, а принимаемые с сигналом флуктуационные помехи создают зашумленность изображения. Диапазон частот, где присутствует отраженный сигнал, определяет полосу прозрачности линии КВ-связи (полосу допустимых рабочих частот). Ее верхней границей является максимально наблюдаемая частота (МНЧ).

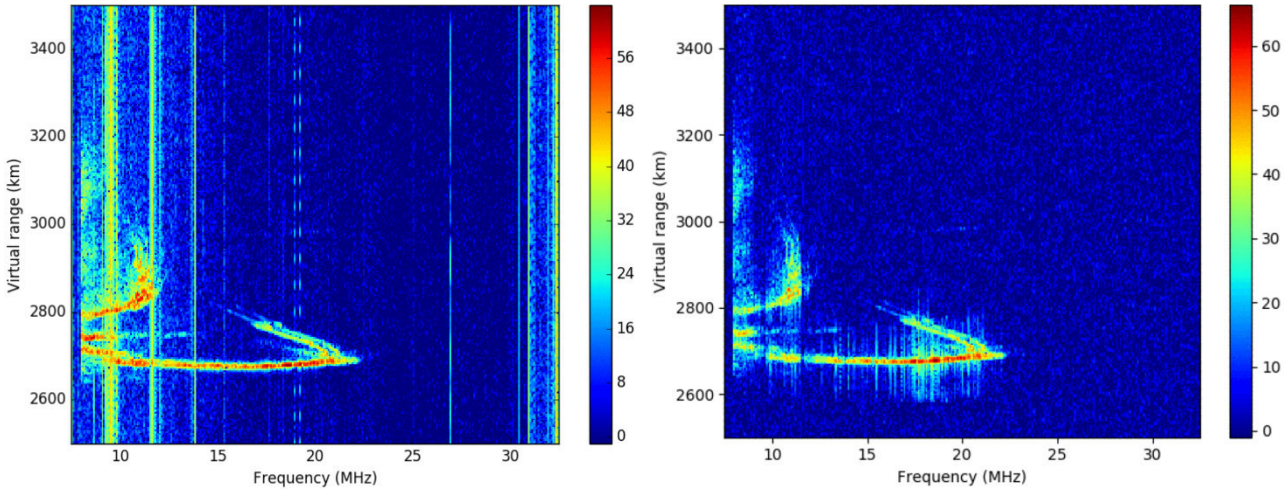

Рис. 5. Ионограммы до обработки (*слева*) и после обработки (*справа*)

Полученное после обработки изображение ионограммы содержит только отсчёты полезного сигнала и фонового шума, близкого к белому. Данные изображения применялись далее для обучения алгоритма автоматического обнаружения принимаемых мод сигнала на основе кластерного анализа данных.

В настоящей работе кластерный анализ является частью разведочного и используется для выделения полезного сигнала при анализе ионограмм наклонного зондирования ионосферы. Ключевой задачей является автоматическое определение групп точек, значение сигнал/шум которых удовлетворяет заданному порогу. Для решения данной задачи применен алгоритм машинного обучения k-means [5]

как наиболее удобный для работы с изображениями. Суть алгоритма заключается в грубом распределении центров кластеров исследуемого набора данных (x_i, y_i), после чего центр $(\overline{x_i}, \overline{y_i})$ l-го кластера вычисляется как

$$\overline{x_l} = \frac{1}{q_l} \sum_{i \in \text{кластер } l} x_i \, , \overline{y_l} = \frac{1}{q_l} \sum_{i \in \text{кластер } l} y_i \, ,$$

где q – суммарный размер массива ионограммы.

Дальнейшее разделение исходной выборки на подвыборки по принципу минимизации суммы квадратов расстояний от каждой точки подвыборки до центра кластера. Сумма квадратов внутри кластера определяется следующим образом:

$$NN_l = \sum_{i \in \text{кластер } l} (x_i - \overline{x_i})^2 + (y_i - \overline{y_i})^2 \, .$$

На следующем этапе итеративно выполняется коррекция центров каждого кластера за счет минимизации дисперсии до достижения заданного порога по точности или по количеству итераций по следующей формуле:

$$\arg\min_N \sum_{i=1}^{l} NN_i$$

где $\arg\min$ – аргумент минимизации; N – набор всех кластеров.

Ионограммы, полученные после предварительной фильтрации шумов, перед применением алгоритма k-means преобразуются в трехмерный массив средствами библиотеки OpenCV (Open Source Computer Vision Library) [11], доступной для использования на языке программирования Python. Полученный массив содержит количество строк, равное высоте изображения (ионограммы), количество столбцов, равное ширине изображения, а каждая ячейка по высоте и ширине содержит значения уровня сигнал/шум, представленного в виде трех значений кодировки цветности по стандарту RGB. Полученный трехмерный массив является входным аргументом для алгоритма k-means. В исследовании использовалась функция «kmeans» библиотеки OpenCV, в параметрах настройки которой задаются требуемое количество кластеров, количество итераций до остановки алгоритма, количество итераций, когда группировка выполнятся заново с использованием разных начальных центров, и тип функции выбора начальной точки кластера.

Результаты экспериментов

Верификация предложенного метода в натурных экспериментах на среднеширотной радиотрассе о. Кипр – г. Йошкар-Ола. В экспериментах анализировались ионограммы с применением различного количества кластеров. В алгоритме машинного обучения диапазон значений числа выбираемых кластеров на изображении изменялся от 5 до 11. В результате экспериментов было установлено, что увеличение количества кластеров модели k-means позволяет более точно выделить границы мод ионограммы с низким отношением сигнал/шум. На рисунке 6 представлены пример оригинального изображения ионограммы после предварительной обработки и результат выделения двух полученных кластеров из 11.

На рисунке 6 (снизу) показан принцип выделения кластеров с максимальными значениями сигнал/шум на изображении ионограммы с помощью представленного в предыдущем пункте алгоритма машинного обучения. Красным цветом отображены варианты сигнала, которые содержат максимальные значения отношения сигнал/шум, оранжевым – зона с меньшим уровнем полезного сигнала. В результате обработки удалено 8 из 11 кластеров. Варианты с низким отношением сигнал/шум (менее 25 дБ) были удалены алгоритмом с изображения.

На рисунке 7 представлена ионограмма, очищенная с использованием идентичных 11 кластеров, но с сохранением уровня более высокого диапазона сигнал/шум. В таком случае алгоритмом детектируется сигнал с низким отношением сигнал/шум (2-5 дБ).

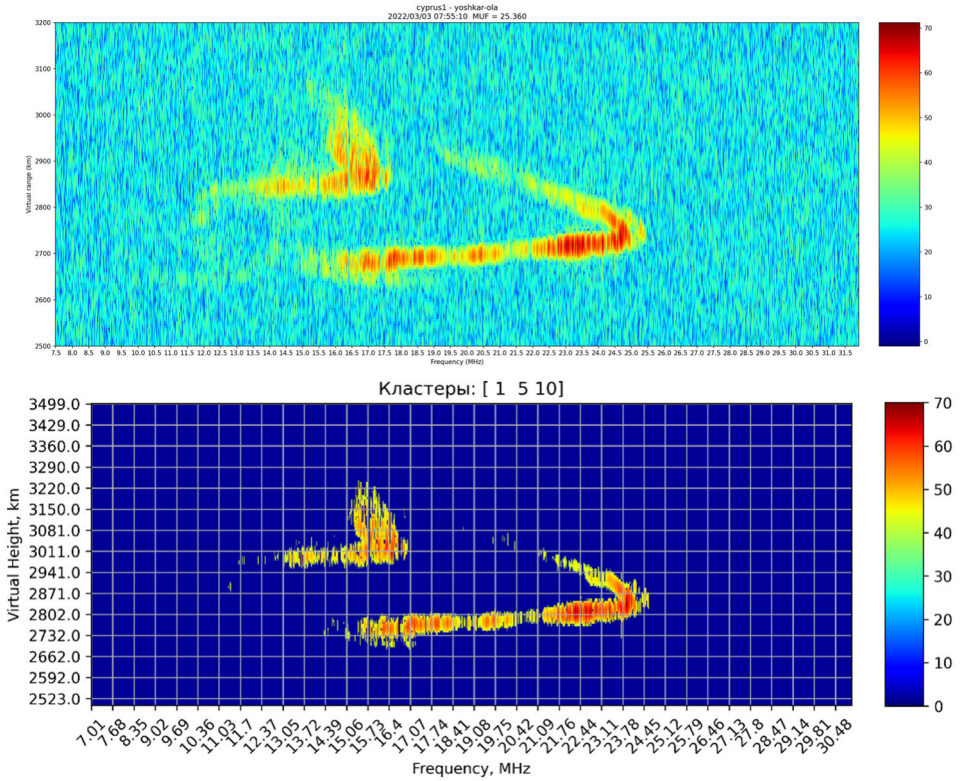

Рис. 6. Ионограммы наклонного зондирования ионосферы: оригинальная ионограмма (*сверху*) и ионограмма (*снизу*) с выделенными кластерами максимального уровня сигнал/шум, очищенная с использованием 11 кластеров

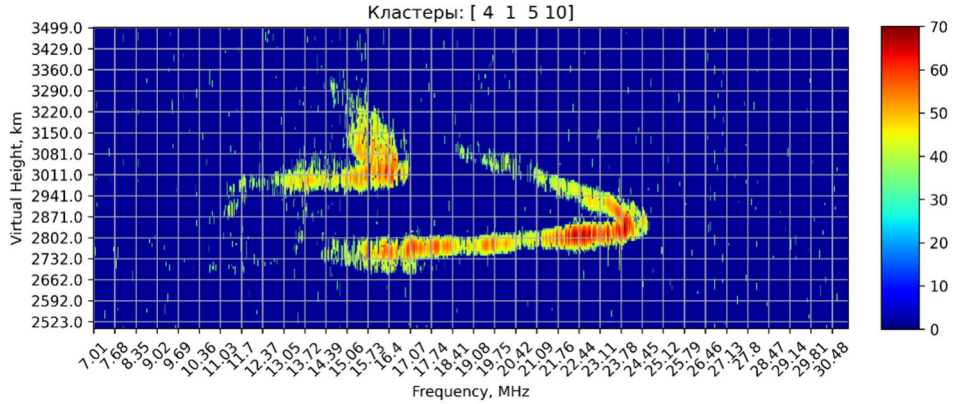

Рис. 7. Ионограммы наклонного зондирования ионосферы, очищенная с использованием 11 кластеров (7 из 11 отфильтрованы), с сохранением сигналов с низким отношением сигнал/шум дБ

Обсуждение результатов

Проведённый анализ влияния входных параметров алгоритма k-means на результат кластеризации показал, что ключевым параметром для настройки является используемое количество кластеров. При выборе количества кластеров от 8 до 11 полезная область ионограммы определяется минимум тремя кластерами, центральным (см. рис. 6), где сосредоточены максимальные значения отношения сигнал/шум и побочными со средним и минимальным уровнем. При количестве кластеров до 7 алгоритм детектирует значительно большее количество сигнала с минимальным отношением сигнал/шум 2-5 дБ за один кластер, но в таком случае отсутствует возможность коррекции побочных составляющих сигнала за счёт добавления или удаления дополнительных кластеров. Полученное после обработки изображение позволяет осуществлять в автоматическом режиме дальнейшие вычисления требуемых параметров коротковолновой линии связи, таких как максимально применимая частота, наименьшая применимая частота, оптимальная радиочастота.

Многочисленные эксперименты, проведённые на трассе о. Кипр – г. Йошкар-Ола, показали, что при использовании количества кластеров от 5 до 7 целесообразно выделять только один кластер, а от 8 до 11 – по три кластера. Обнаружение вариант с минимальными потерями полезного сигнала достигается при использовании 11 кластеров. Для автоматизации вычисления номера кластера, который несет полезное значение сигнал/шум, вычисляется средний уровень отношения сигнал/шум [12] по точкам кластера с последующим выбором двух максимальных.

Заключение

При зондировании многомерного КВ-радиоканала и ионосферы возникает задача автоматической обработки изображений ионограмм с целью выделения полезного сигнала над помехами. Ее сложность заключается в необходимости учета изменчивости помеховой обстановки за время не менее 10 с, изменчивости среды распространения за время, не меньшее 5 мин. Для решения задачи в работе предложен комплексный метод обнаружения принимаемых мод сигнала на изображении ионограммы с применением алгоритмов обеляющего эквалайзирования ВЧ-сигнала, медианного эквалайзирования сигнала после его сжатия и машинного обучения на основе кластерного анализа изображений ионограмм.

Экспериментально показано, что предварительная обработка алгоритмами обеляющего и медианного эквалайзирования стандартизирует функции распределения вариант отсчётов сигнал+шум, уменьшая разброс значений от 50 до 2 дБ. В натурных экспериментах исследовалось применение различного числа кластеров изображения ионограммы для автоматического обнаружения сигнала. Многочисленные эксперименты, проведённые на трассе о. Кипр – г. Йошкар-Ола, показали, что при использовании количества кластеров от 5 до 7 целесообразно выделять только один кластер, а от 8 до 11 – по три кластера. Обнаружение вариант с минимальными потерями полезного сигнала достигается при использовании 11 кластеров.

Предложенный метод может быть внедрён в состав когнитивных радиосенсоров и систем адаптивной радиосвязи. В перспективе работа может быть расширена с применением сверточных нейросетей или гибридных подходов с предварительной кластеризацией.

Источник финансирования

Работа выполнена при финансовой поддержке Российского научного фонда, грант (Теория, методы и средства сенсорной диагностики доступности каналов когнитивной КВ радиосвязи с учетом частотно-временной дисперсии, канальных помех и с применением технологий программно-конфигурируемых радиосистем и анализом больших данных, №24-29-00442).

Список литературы

1. A. Bruce, P.C. Bruce, and P. Gedeck, “Practical Statistics for Data Scientists,” O'Reilly Media, Inc., 2020 (ISBN 10: 9781491952962).

2. H. Singh, “Practical Machine Learning and Image Processing: For Facial Recognition, Object Detection, and Pattern Recognition Using Python,” Apress, February 2019 (ISBN 10: 9781484241493).

3. C. De La Jara, and C. Olivares, “Ionospheric echo detection in digital ionograms using convolutional neural networks,” Radio Science, vol. 56, no. 8, pp. 1-15, Aug. 2021, doi: 10.1029/2020RS007258.

4. V.A. Ivanov, D.V. Ivanov, N.V. Ryabova, M.I. Ryabova, A.A. Chernov, A.A. Elsukov, “Computer filtering of images of ionograms of HF ionospheric radio communication paths and an algorithm for determining signal-to-noise ratio,” Journal of Applied Engineering Science, 16(1), pp. 116–124, 2018. doi: 10.5937/jaes16-11790.

5. J. Grus, “K-means and hierarchical clustering with Python,” O'Reilly Media, Inc., August 2016 (ISBN 10: 9781491966174).

6. P. Benchawattananon, A. Siritaratiwat, P. Supnithi, et al. “Automatic classification of spread-F types in ionogram images using support vector machine and convolutional neural network”, Earth Planets Space 76, 56, 2024.

7. V.A. Ivanov, D.V. Ivanov, N.V. Ryabova, M.I. Ryabova, A.A. Chernov, and A.A. Elsukov, “Algorithms and software of whitening of noise in the reception of broadband chirp signals in the HF communication channel,” Journal of Applied Engineering Science, 13(4), pp. 245–250, 2015. doi: 10.5937/jaes13-9342.

8. D.V. Ivanov, V.A. Ivanov, A.A. Elsukov, N.V. Ryabova, V.V. Ovchinnikov, and M.I. Ryabova “Algorithms of adaptive narrow-band interferences suppression and automatic signal detection for swept-frequency sounding of multiple HF radio channels,” URSI AP-RASC 2019, New Delhi, India, 09 - 15 March 2019.

9. H.M. Finn and R.S. Johnson, “Adaptive detection mode with threshold control as a function of spatially sampled clutter level estimates,” RCA Rev., vol. 29, no. 3, pp. 414–464.

10. D. Ivanov, V. Ivanov, N. Ryabova, N. Konkin, and V. Ovchinnikov, "Method for Detecting Modes of Received Echo Signal on Image of Ionogram of Radio Sounding with the Use of Machine Learning," 2022 Wave Electronics and its Application in Information and Telecommunication Systems (WECONF), St. Petersburg, Russian Federation, 2022, pp. 1-5, doi: 10.1109/WECONF55058.2022.9803515.

11. OpenCV. (2022, April 13). Open Source Computer Vision Library: OpenCV modules. https://docs.opencv.org/4.x/

12. D.V. Ivanov, V.A. Ivanov, R.R. Belgibaev, and A.R. Laschevsky, “Adaptive Algorithms for Filtering Ionograms and Measuring Channel Parameters to Estimate its Availability,” 2019 Systems of Signal Synchronization, Generating and Processing in Telecommunications (SYNCHROINFO), 2019, pp. 1-4, doi: 10.1109/SYNCHROINFO.2019.8813917.