

13. A.-L. Barabási, R. Albert. (1999). Emergence of scaling in random networks. *Science* 286 (5439). P. 509–512
14. K. Coronges, A.-L. Barabási, A. Vespignani. Future Directions of Network Science. A Workshop Report on the Emerging Science of Networks. September 29–30, 2016. - 35 p
15. NETWORK SOCIETY: AGGREGATE TOPOLOGICAL MODELS Tikhomirov A., Afanasyev A., Kinash N., Trufanov A., Berestneva O., Rossodivita A., Gnatyuk S., Umerov R. *Communications in Computer and Information Science*. 2014. T. 487. C. 415-421.
16. ANALYSIS OF LARGE-SCALE NETWORKS USING HIGH PERFORMANCE TECHNOLOGY (VKONTAKTE CASE STUDY) Kinash N., Trufanov A., Tikhomirov A., Ashurova Z., Berestneva O., Boukhanovsky A. *Communications in Computer and Information Science*. 2015. T. 535. C. 531-541.
17. An introduction to deception technology. TrapX Security. TrapX Software. 2015.-2 p.  
URL: [https://www.xtelesis.com/wp-content/uploads/2015/07/Data-Sheet\\_Intro\\_to\\_Deception\\_Technology\\_v2.11.2015.pdf](https://www.xtelesis.com/wp-content/uploads/2015/07/Data-Sheet_Intro_to_Deception_Technology_v2.11.2015.pdf).

### СЕТЕВЫЕ ПРИЗНАКИ НАЛИЧИЯ МОНТАЖА АУДИОСИГНАЛА

*Д.Г.Портнягин<sup>1</sup>, Е.И.Кравчук<sup>1</sup>, А.И.Труфанов<sup>2</sup>, А.С.Иванов<sup>2</sup>, О.Г.Берестнева<sup>3</sup>,  
А.А.Тихомиров<sup>4</sup>*

*<sup>1</sup>(г. Иркутск, ЭКО СУ СК России по Иркутской области)  
e-mail: dportn@yandex.ru*

*<sup>2</sup>(г. Иркутск, Иркутский Национальный  
исследовательский технический университет)*

*<sup>3</sup>(г. Томск, Томский политехнический университет)*

*<sup>4</sup>(г. Инчон, РК, Университет Инха)*

### NETWORK MARKS OF MONTAGE IN AUDIO RECORDINGS

*D.G.Portnyagin<sup>1</sup>, E.I.Kravchuk<sup>1</sup>, A.I.Trufanov<sup>2</sup>, A.S.Ivanov<sup>2</sup>, O.G.Berestneva<sup>3</sup>, A.A.Tikhomirov<sup>4</sup>*

*<sup>1</sup>(Irkutsk Investigative Office in Irkutsk Region, IC RF)*

*<sup>2</sup>(Irkutsk, Irkutsk National Research Technical University)*

*<sup>3</sup>(Tomsk, Tomsk Polytechnic University)*

*<sup>4</sup>(Incheon, RK, Inha University)*

**Abstract.** In forensic domain, it is often arisen a task of approval of authenticity in audio recordings presented as admissible evidence. Standard techniques to search for editing in audio materials are rather long and wearisome. In this paper, a network platform has been proposed as an effective tool for solving this problem. The results demonstrate the first advances of network paradigm for detection of audio montage, also examples of trivial signals of those point on possible existence of a marker - the metric that responds to sound recordings tampering.

**Keywords:** audio forensics, audio authenticity, complex networks, detection of montage, marks of tampering, network metrics.

**Введение.** Одной из задач, возникающих при проведении фоноскопической криминалистической экспертизы, является определение монтажа в аудиозаписях, представленных в качестве доказательства [1]. Стандартная методика определения наличия/отсутствия монтажа в аудиозаписи представляет собой достаточно длительный и трудоемкий процесс [2]. Учитывая, что любой аудиосигнал можно представить в виде суперпозиции гармонических сигналов, различных частот [3], при тестировании традиционных или разрабатываемых подходов анализа аудиоматериала разумно исследовать влияние монтажа на каждую из частот и комбинации частот, кратных и некратных друг другу. Выявив общие закономерности для

одной частоты или суперпозиции двух и более частот, как кратных друг другу, так и не являющихся кратными, синтезировав данные закономерности, можно интерполировать их для определения наличия монтажа в любом исследуемом аудиосигнале.

Интересно, что в последние двадцать лет для исследования разнообразных сложных систем был развит и все в большей степени привлекается такой инструмент как комплексные сети [4-7]. При этом, общий подход к анализу временных рядов с отображением их сетевой структуры [8-10] годен для применения ко многим динамическим системам, в том числе и для аудиопотоков.

Следует понимать, что анализ сигнала, подразумевает собой представление исходного сигнала в виде сетевой модели и последующий анализ основных сетевых метрик, неоднородность которых будет сигнализировать о наличии монтажа в исследуемом сигнале. Интересно, что модели, применяемые в отношении к звуковым данным, все еще являются российской экзотикой в изучении звуковой информации в целом [11-12]. В то же время в мировой исследовательской практике они применяются для различного рода аудиоданных, в том числе речевых, музыкальных и звуков различного происхождения [13-17].

**Метод и инструмент исследования.** Задача анализа аудиосигнала изначально подразделялась на две подзадачи: преобразование исходных данных (монофонического или стереофонического аудиосигнала) в сетевую структуру и анализ полученных сетевых структур с целью выявления метрик и параметров, индицирующих наличие монтажа.

Для преобразования исходных данных был разработан специализированный программный продукт, позволяющий преобразовывать исследуемые аудиоданные в таблицы вершин и ребер графа по алгоритмам прямой и горизонтальной видимости [8]. Общий вид рабочего окна данной программы приведен на рис. 1.




Рис. 1. Рабочее окно программы преобразования аудиосигнала в таблицы узлов и ребер.

**Данные.** В качестве тестовых примеров были выбраны сигналы, содержащие одну, две, четыре и восемь гармоник. Сигнал содержит:

- одну гармонику частотой 1000 Гц (рис.2);

- две гармоники частотами 500 и 1000 Гц (рис.4);
  - четыре гармоники с частотами 500, 1000, 1300 и 1900 Гц (рис.6);
  - восемь гармоник с частотами 500, 1000, 1300, 1500, 1900, 2000, 2300 и 2900 Гц (рис.8).
- И монтаж сигналов тех же частот (рис. 3, 5, 7, 9).




Рис.2. Сигнал частотой 1000 Гц




Рис.3. Сигнал частотой 1000 Гц с монтажом




Рис.4. Сигнал с частотами 500 и 1000 Гц




Рис.5. Сигнал с частотами 500 и 1000 Гц с монтажом




Рис.6. Сигнал с частотами 500, 1000, 1300 и 1900 Гц




Рис.7. Сигнал с частотами 500, 1000, 1300 и 1900 Гц с монтажом




Рис.8. Сигнал с частотами 500, 1000, 1300, 1500, 1900, 2000, 2300 и 2900 Гц




Рис.9. Сигнал с частотами 500, 1000, 1300, 1500, 1900, 2000, 2300 и 2900 Гц с монтажом

**Основные результаты.** Представленные тестовые сигналы были преобразованы в графовую структуру по алгоритмам прямой (рис.10) и горизонтальной видимости (рис.11) и дальнейший сравнительный анализ полученных сетевых структур проводился с применением программного продукта Gephi [18]. При анализе сравнивались метрики, характерные для

неизменного сигнала и метрики сигнала, содержащего монтаж. Полученные сетевые структуры визуализировались с применением укладки «Yifan Hu».

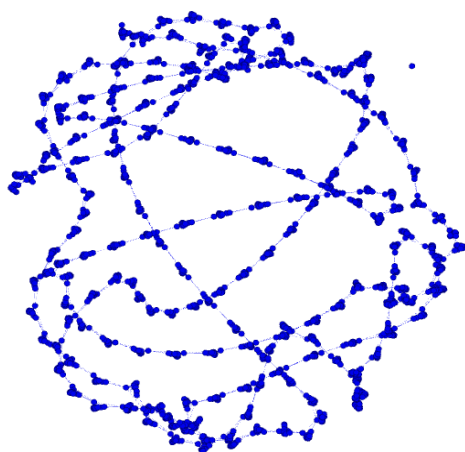


Рис.10. Визуализация сетевой структуры для алгоритма прямой видимости.




Рис.11. Визуализация сетевой структуры для алгоритма горизонтальной видимости.

**Обсуждение.** Существенный объем проведенных расчетов позволил сравнить различные статистические параметры и метрики сетевых отрисовок, тестируемых аудиосигналов. Следует отметить, что визуально наиболее ярко монтаж проявляется при применении алгоритма преобразования исходного сигнала в сетевую структуру по алгоритму «Горизонтальной видимости» для метрики «Eccentricity Distribution» (рис. 12-19).

Важно подчеркнуть, что остальные метрики, проанализированные в настоящем исследовании, не дают однозначной идентификации наличия монтажа в тестовых аудиосигналах.




Рис.12. Метрика «Eccentricity Distribution» для сигнала с частотой 1000 Гц




Рис.13. Метрика «Eccentricity Distribution» для сигнала с частотой 1000 Гц, содержащей монтаж.




Рис.14. Метрика «Eccentricity Distribution» для сигнала с частотами 500 и 1000 Гц




Рис.15. Метрика «Eccentricity Distribution» для сигнала с частотами 500 и 1000 Гц, содержащим монтаж.

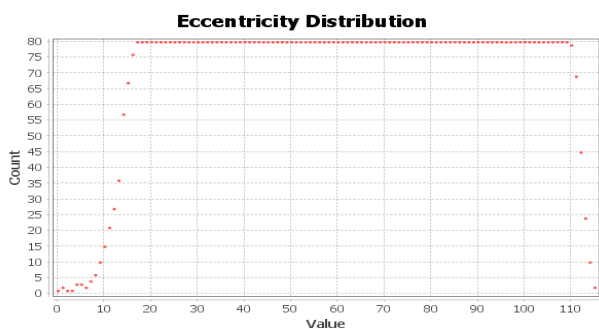


Рис.16. Метрика «Eccentricity Distribution» для сигнала с частотами 500, 1000, 1300 и 1900 Гц




Рис.17. Метрика «Eccentricity Distribution» для сигнала с частотами 500, 1000, 1300 и 1900 Гц, содержащим монтаж.




Рис.18. Метрика «Eccentricity Distribution» для сигнала с частотами 500, 1000, 1300, 1500, 1900, 2000, 2300 и 2900 Гц




Рис.19. Метрика «Eccentricity Distribution» для сигнала с частотами 500, 1000, 1300, 1500, 1900, 2000, 2300 и 2900 Гц, содержащим монтаж.

При применении данного подхода к анализу признаков монтажа для более сложного аудиосигнала, представляющего собой музыкальный фрагмент, с внесенными изменениями, метрика «Eccentricity Distribution» не дает однозначного ответа о присутствии монтажа (рис.20-21).




Рис.20. Метрика «Eccentricity Distribution» для музыкального фрагмента длительностью 1 сек.

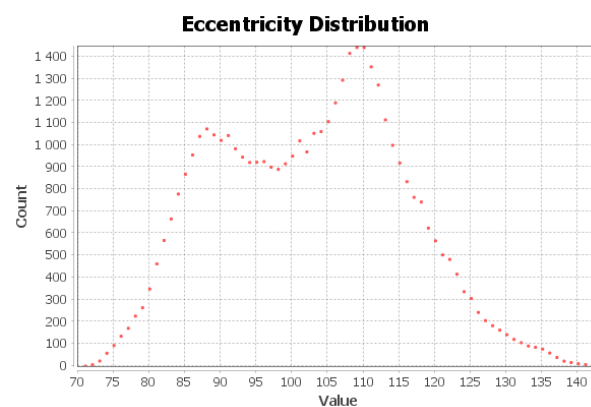


Рис.21. Метрика «Eccentricity Distribution» для музыкального фрагмента длительностью 1 сек, содержащего монтаж.

**Выводы.** Результаты настоящего исследования продемонстрировали первые успехи на пути использования сетевой платформы для определения признаков монтажа, а также на примере тривиальных сигналов возможного существования маркера - метрики, реагирующей на монтаж аудиозаписи. Однако, утверждать о принципиальном решении задачи даже в рамках данных простейших сигналов рано. Наука о сетях (Network Science) [4] предоставляет исследователю мощный инструмент для анализа, но и требует от него глубокого знания прикладной предметной области, творческого подхода, изобретательности и нестандартных

приемов по предварительной обработке данных для создания релевантных онтологий, на основании которых далее эти данные трансформируются в сетевые структуры.

#### ЛИТЕРАТУРА

1. Korycki R. Authenticity examination of compressed audio recordings using detection of multiple compression and encoders' identification. *Forensic Science International*, 238, - 2014-р.33–46.
2. Техничко-криминалистическое исследование звукозаписей. Методика выявления признаков изменения фонограммы, оригинальности и непрерывности процесса звукозаписи «ДУЭТ». ФСБ России. Центр специальной техники. Институт криминалистики. - Издание 2-е, переработанное. - 52 с.
3. Гоноровский И. С. Радиотехнические цепи и сигналы: Учебник для вузов. — 4-е изд., перераб. и доп. — М.: Радио и связь, 1986. — 512 с.
4. Vespignani, A.: Twenty years of network science. *Nature* 558, - 2018.- p.528–529.
5. Boccaletti S., Latora V., Moreno Y., Chavezf M., Hwang D.-U. Complex networks: Structure and dynamics .*Physics Reports*. Vol. 424. -2006. - p.175–308.
6. Costa, L. da F., Rodrigues, F. A., Traverso, G., & Villas Boas, P. R. Characterization of complex networks: A survey of measurements. *Advances in Physics*, 56(1) -2007. – p.167–242.
7. De Domenico M, Porter M.A, Arenas A. MuxViz: a tool for multilayer analysis and visualization of networks. *Journal of Complex Networks*. –Vol 3. -2015. - p.159-176.
8. Lacasa, L., Luque, B., Ballesteros, F., Luque, J., & Nuño, J. C. From time series to complex networks: The visibility graph. *Proceedings of the National Academy of Sciences*, 105(13), - 2008. – p. 4972–4975.
9. Zhang Z., Xu J., Zhou X. Mapping time series into complex networks based on equal probability division. *AIP Advances* 9, 015017 -2019. - 10 p.
10. Yela F., Thalmann F., Nicosia V., Stowell D., Sandler M. Efficient On-line Computation of Visibility Graphs Delia. arXiv: 1905.03204v1 [cs.DS] - 2019 - 9 p.
11. Портнягин Д.Г., Себякин А.Г., Куулар Э.К., Труфанов А.И., Берестнева О.Г., Тихомиров А.А. Программное обеспечение, используемое для определения признаков монтажа видеозаписей. Сб. научных трудов V Международной научной конференции «Информационные технологии в науке, управлении, социальной сфере и медицине». В 2-х частях. Часть 2 (Ред. Берестнева О.Г., Мицель А.А., В.В.Спицын, Гладкова Т.А.), Томский политехнический университет. – Томск: Изд-во Томского политехнического университета, -2018. - с.138-141.
12. Куулар Э.К., Тихомиров А.А., Труфанов А.И. Двухкомпонентная сетевая модель в технологиях голосовой идентификации личности // Безопасность информационных технологий. 2018. № 1. С. 81-89
13. Liu X., Tse C.K., Small M. Composing music with complex networks. *International Conference on Complex Sciences: Theory and Applications, (COMPLEX2009)*, Shanghai, - 2009 – p. 2196-2205.
14. Yang Q., Gao Q., Fan R. A transformation from a singing voice to complex network using correlation coefficients of audio signals. 2011 2nd International Conference on Intelligent Control and Information Processing. -2011. –p. 929-930
15. Hurtado-Jaramillo J. S., Guarin D. L., Orozco A. Complex networks: Application to pathology detection in voice signals. 2012 Annual International Conference of the IEEE Engineering in Medicine and Biology Society. -2012 – p. 4229-4232.
16. Ferretti S. On the complex network structure of musical pieces: analysis of some use cases from different music genres. *Multimedia Tools and Applications*, 77(13), -2017. –p. 16003–16029.
17. Melo D. de F. P., Fadigas I. de S., de Barros Pereira H. B. Categorisation of polyphonic musical signals by using modularity community detection in audio-associated visibility network.

## ИСПОЛЬЗОВАНИЕ ОБЛАЧНЫХ ТЕХНОЛОГИЙ МАШИННОГО ОБУЧЕНИЯ В СОЦИАЛЬНЫХ ИССЛЕДОВАНИЯХ С ОГРАНИЧЕННЫМ ФИНАНСИРОВАНИЕМ

*С.В. Романчуков*

*(г. Томск, Томский политехнический университет)*

*e-mail: inoytomsk@yandex.ru*

## CLOUD-BASED MACHINE LEARNING PLATFORMS FOR SOCIAL RESEARCH LOW ON RESOURCES

*S.V. Romanchukov*

*(Tomsk, Tomsk Polytechnic University)*

**Abstract:** Actual paper compares machine learning cloud platforms that can be used by non-programmers, it is addressed to sociologists, psychologists, gender researchers. Their work can require more of a data scientific approach, than their funds can allow to support. This tools can be used with minor expertise in the field of machine learning, programming and mathematics and don't require professional data scientists and analysts in team. We take one testing data set similar to those generated in field-level social studies and fallow through every stage of model training and tweaking in Google Cloud AI and IBM Watson Auto AI - two cloudbased platforms for data science without engineering.

**Keywords:** cloud platform, classification, machine learning

**Введение.** Машинное обучение и искусственные нейронные сети достаточно эффективны в решении задач классификации, распознавания образов, прогнозирования поведения сложных систем и выбора неизвестных параметров, которые связаны с характеристиками сложных объектов, в том числе социально-экономических систем [1]. Существует несколько методов так называемого «обучения» нейронной сети: обучение с учителем, обучение без учителя, обучение с подкреплением [2].

Первый вариант - обучение с учителем (способ реализации машинного обучения, при котором тестовая система подвергается принудительному обучению с использованием примеров «стимул-реакция») - кажется наиболее подходящим для решения проблемы взаимосвязи между двумя группами параметров, классификация или прогнозирования параметров[3].

Метод обучения с учителем предполагает, что может быть некоторая неустановленная связь между входными и выходными данными. Известен только конечный набор прецедентов - пар стимул-реакция - называемая обучающим набором. На основе этих данных происходит итеративный процесс выбора параметров с целью восстановления зависимости и построения подходящей для прогнозирования модели отношений [4].

Организация процесса обучения с нуля является нетривиальной математической и программистской задачей, однако на данный момент на рынке доступно значительное количество облачных программных продуктов, которые позволяют создавать проекты AI и ML без специальных знаний. Исследовательские группы с ограниченным финансированием, лишённые доступа к профессиональным знаниям в этой области могут использовать такие решения, однако, чтобы подходить упомянутой аудитории, программный продукт должен отвечать нескольким дополнительным требованиям, кроме точности и технических параметров:

- Простая и доступная документация и пользовательский интерфейс
- Простота использования и интерпретации результатов