

Научная статья
УДК 004.67:519.246.8
doi: 10.34822/1999-7604-2022-4-37-48

АНАЛИЗ СТРУКТУРЫ ВРЕМЕННЫХ РЯДОВ КОЛИЧЕСТВА ДЕЛ В СУДЕ

Василий Александрович Громов¹, Петр Павлович Лукьянченко²,
Юрий Николаевич Бесчастнов³✉, Корней Кириллович Томащук⁴

^{1, 2, 3, 4} Национальный исследовательский университет «Высшая школа экономики»,
Москва, Россия

¹ stroller@rambler.ru, <https://orcid.org/0000-0001-5891-6597>

² lukianchenko.pierre@gmail.com, <https://orcid.org/0000-0002-1022-6041>

³ y.beschastnov@mail.ru ✉

⁴ korneytomashchuk@yandex.ru

Аннотация. Проведен анализ временных рядов количества новых дел в административных судах РФ двумя методами группировки временных рядов с учетом хаотичности, случайности и регулярности их структуры. Первая модель основана на плоскости «энтропия – сложность», вторая – граф «атрибут – объект». Выведено четыре группы временных рядов: регулярные, регулярные-хаотические, строго хаотические и хаотические-стохастические, из которых хаотические-стохастические оказались в большинстве, что свойственно реальным системам. Для каждой группы предложен алгоритм прогнозирования в соответствии со структурой ряда, например, для хаотических рядов – алгоритмы нелинейной динамики, а для сильно стохастических рядов – модели, основанные на случайных процессах.

Ключевые слова: временные ряды, энтропия – сложность, анализ формальных понятий

Финансирование: публикация подготовлена за счет средств гранта на поддержку исследовательских центров в сфере искусственного интеллекта, в том числе в области «сильного» искусственного интеллекта, систем доверенного искусственного интеллекта и этических аспектов применения искусственного интеллекта, предоставленного АНО «Аналитический центр при Правительстве Российской Федерации» в соответствии с соглашением о предоставлении субсидии (идентификатор соглашения о предоставлении субсидии 000000D730321P5Q0002) и договором с ФГАОУ ВО «Национальный исследовательский университет «Высшая школа экономики» от 2 ноября 2021 г. № 70-2021-00139.

Для цитирования: Громов В. А., Лукьянченко П. П., Бесчастнов Ю. Н., Томащук К. К. Анализ структуры временных рядов количества дел в суде // Вестник кибернетики. 2022. № 4 (48). С. 37–48. DOI 10.34822/1999-7604-2022-4-37-48.

Original article

TIME SERIES STRUCTURE ANALYSIS OF THE NUMBER OF LAW CASES

Vasily A. Gromov¹, Petr P. Lukyanchenko²,
Yury N. Beschastnov³✉, Korney K. Tomashchuk⁴

^{1, 2, 3, 4} National Research University Higher School of Economics, Moscow, Russia

¹ stroller@rambler.ru, <https://orcid.org/0000-0001-5891-6597>

² lukianchenko.pierre@gmail.com, <https://orcid.org/0000-0002-1022-6041>

³ y.beschastnov@mail.ru ✉

⁴ korneytomashchuk@yandex.ru

Abstract. The study analyzes the time series of the number of new cases in the administrative courts of the Russian Federation using two methods of time series grouping according to the chaotic, stochastic, and regular structure. The first model is based on the entropy–complexity plane, the second one is presented by the attribute–object graph. As a result, four groups of time series were derived: regular, regular-chaotic, purely chaotic, and chaotic-stochastic. Most of the series turned out to be chaotic-stochastic, which is common for

real systems. Each group of time series is assigned with a suitable prediction algorithm. For example, algorithms of nonlinear dynamics can be used for chaotic series, and models based on stochastic processes can be used for strongly stochastic series.

Keywords: time series, entropy–complexity, formal concept analysis

Funding: the article was supported by the grant for research centers in the field of AI, strong AI, trusted AI systems, and AI ethics provided by the Analytical Center for the Government of the Russian Federation in accordance with the agreement on the provision of subsidies (identifier of the agreement 000000D730321P5Q0002) and the agreement with the National Research University Higher School of Economics No. 70-2021-00139 of November 2, 2021.

For citation: Gromov V. A., Lukyanchenko P. P., Beschastnov Yu. N., Tomashchuk K. K. *Time Series Structure Analysis of the Number of Law Cases // Proceedings in Cybernetics. 2022. No. 4 (48). P. 37–48. DOI 10.34822/1999-7604-2022-4-37-48.*

ВВЕДЕНИЕ

Ежегодно арбитражные суды России рассматривают более 2 миллионов дел, их количество ежегодно увеличивается, при этом нагрузка судей по регионам сильно разнится, и даже в одном регионе она может существенно отличаться от месяца к месяцу. В некоторых регионах на судью приходится не более 70 дел в месяц, в других – более 250, а из-за неравномерности возникновения правовых нарушений возникает ситуация, когда один арбитражный суд имеет в распоряжении судей больше чем нужно, в то время как в других регионах судей недостаточно. Таким образом, прогнозирование количества дел в арбитражных судах России чрезвычайно важная задача, математически формулируемая как задача прогнозирования сложных временных рядов.

Мы имеем сильно отличающиеся друг от друга по структуре 3 149 рядов как регулярных, так и хаотических с сильной случайной компонентой (рис. 1). Учитывая, что построение единой для всех рядов прогнозной модели получения адекватного прогноза невозможно, важно определить их сложность и тип, например, регулярные ряды могут быть предсказаны с помощью авторегрессионных моделей, а для хаотических рядов данные методы приводят к экспоненциальному росту ошибки [1].

Проведено исследование сложности временных рядов, описывающих количество новых дел в арбитражных судах. Для разделения рядов на регулярные, хаотические и стохастические использован метод вычисления характеристик энтропии и сложности

для множества ординальных структур рассматриваемого временного ряда и анализ положения соответствующей точки на плоскости «энтропия – сложность», а также метод анализа формальных понятий [2], основанный на построении графа «атрибут – объект», который позволяет не только различить ряды между собой, но также представить структуру ряда. С помощью этих методов удалось разбить ряды на группы по их сложности и выраженности случайной компоненты, что крайне важно при прогнозировании и выборе методов прогнозирования для того или иного ряда.

При проведении исследования учитывались новые способы и методы вычисления, например, метод вычисления наибольшего показателя Ляпунова из временного ряда [3]. Метод опирается на определения старшего показателя Ляпунова, а алгоритм устойчив к изменениям следующих параметров: размер выборки, размерность вложение данных, окно реконструкции и уровень шума. Кроме того, можно использовать алгоритм для одновременного вычисления корреляционной размерности, т. е. одна последовательность вычислений представляет оценку как уровня хаоса, так и сложности системы.

Популярным новым инструментом для обнаружения хаоса во временных рядах является тест 0–1 (G. A. Gottwald, I. Melbourne) [4]. В отличие от методов касательного пространства, знание полного пространства состояний не требуется, так как реконструкция пространства состояний является необязательной процедурой, поэтому метод можно использовать для данных, у которых не все переменные со-

рования и ненулевой взаимной корреляцией). Авторы используют стабильность устойчивых гомологий в присутствии шума, чтобы представить метод для определения точек сдвига между хаотической и регулярной динамикой в умеренно зашумленных временных рядах.

Иной подход для определения типа временных рядов основывается на понятии ординальной структуры и представлении временного ряда точкой на плоскости «энтропия – сложность» и позволяет различать сложные детерминированные (хаотические) временные ряды, простые детерминированные (хаотические) временные ряды и стохастические временные ряды [8].

В [9] представлен метод, который использовался для выявления хаотических, случайных и регулярных структур во временных медицинских рядах. Алгоритм построен на основе выявления сообществ в графе и анализа формальных понятий, а количеством определенных структур графа описывалось поведение ряда.

МАТЕРИАЛЫ И МЕТОДЫ

Постановка задачи. Дано множество рядов – необходимо различать хаотичную, стохастическую и регулярную структуры рядов. Пусть $x_t = f(\{\varepsilon_s\}_{s=0}^t, \{x_s\}_{s=0}^{t-1}, t)$ – значение ряда в момент времени t , где ε_s – стохастический процесс, f – функция перехода. Тогда:

1. Условие регулярности ряда:

$$\text{одновременно } \{\varepsilon_s\}_{s=0}^{t-1} = 0 \\ \text{и } \forall t \|\lambda(D_x f(\{\varepsilon_s\}_{s=0}^t, \{x_s\}_{s=0}^{t-1}, t))\|_\infty < 1.$$

2. Условия стохастичности ряда:

$$\varepsilon_s \text{ – стохастический процесс.}$$

3. Условие хаотичности ряда:

$$\text{одновременно } \{\varepsilon_s\}_{s=0}^{t-1} = 0 \\ \text{и } \forall t \|\lambda(D_x f(\{\varepsilon_s\}_{s=0}^t, \{x_s\}_{s=0}^{t-1}, t))\|_\infty > 1,$$

где $u_{t+1} = D_x f(\{\varepsilon_s\}_{s=0}^t, \{x_s\}_{s=0}^{t-1}, t) = \delta^{-1}(f(\{\varepsilon_s\}_{s=0}^t, \{x_s\}_{s=0}^{t-1}, x_0 + \delta u_t, t) - f(\{\varepsilon_s\}_{s=0}^t, \{x_s\}_{s=0}^{t-1}, x_0, t))$ при

$\delta \rightarrow 0$ [10], $\|\lambda(A)\|_\infty$ – максимальное собственное значение матрицы A .

Для решения задачи выявления различий в структуре временных рядов были использованы энтропийные методы и алгоритмы, основанные на графах. Энтропийный метод отображает рассматриваемый ряд в точку плоскости «энтропия – сложность».

Метод «энтропия – сложность». О. А. Rosso и соавт. [8] был предложен метод, позволяющий отличить хаотические, регулярные и случайные ряды. Алгоритм опирается на вероятностное распределение ординальных структур, построенных по временному ряду $\{y_i\}$. Для данного z -вектора длины n $d_i = (y_{i-(n-1)}, y_{i-(n-2)}, \dots, y_{i-1}, y_i)$, где y_k это k -е наблюдение ряда, строится бинарный вектор размерности $n - 1$ такой, что в i компоненте вектора ставится 1, если i компонента действительного вектора \leq компоненты этого же вектора на $i + 1$ месте.

Указанный вектор носит название ординальной структуры, соответствующей данному действительному вектору. Алгоритм для построения вероятностного распределения порядковых номеров для временного ряда состоит из следующих этапов:

1. Для каждого z -вектора временного ряда вычисляем соответствующую ему ординальную структуру d_i .

2. Строим эмпирическое распределение вероятностей появления ординальных структур в ряде P_i .

3. Для распределения вычисляется энтропия (1) и сложность (2):

$$H[P] = \frac{S[P]}{S_{\max}}, \quad (1)$$

$$C[P] = Q[P, P_e] \cdot H[P], \quad (2)$$

где $S[P] = -\sum_{i=1}^n P_i \cdot \ln(P_i)$, $S_{\max} = \ln(n!) = S[P_e]$, P_e – равномерное распределение; $Q[P, P_e] = Q_0 \cdot \left(S\left[\frac{P+P_e}{2}\right] - S\left[\frac{P}{2}\right] - S\left[\frac{P_e}{2}\right] \right)$, Q_0 – дивергенция Дженсен – Шеннона между данным и равномерным распределением, а Q_0 – коэффициент нормализации.

Описанная выше процедура отображает временной ряд в точку на плоскости «энтропия – сложность». Положение точки относительно нижней и верхней теоретических границ указывает на тип рассматриваемого ряда [9].

Простые детерминированные процессы дадут точку, расположенную в левом нижнем углу фигуры, ограниченной верхней и нижней теоретическими границами (рис. 2).

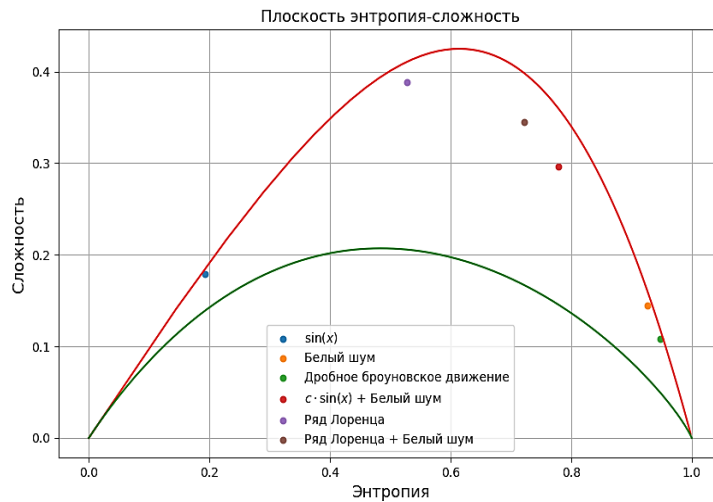


Рис. 2. Стохастические (зеленый, оранжевый), хаотический (фиолетовый), регулярный (синий), регулярный с шумом (красный), хаотический с шумом (коричневый)
 Примечание: составлено авторами на основании данных, полученных в исследовании.

С помощью алгоритмов кластеризации можно осуществить кластеризацию точек на плоскости «энтропия – сложность» и выявить группы временных рядов различных типов.

В рамках анализа формальных понятий был предложен другой подход к различению регулярных рядов от хаотических – построение графа «атрибут – объект» [9]. В методе предполагается построение выборки по нормализо-

ванному временному ряду, бинаризация атрибутов, характеризующих элементы выборки, построение графа «атрибут – объект», анализ характеристик указанного графа с целью различения графов, соответствующих регулярным и хаотическим временным рядам. Пример характерного графа «атрибут – объект» представлен на рис. 3.

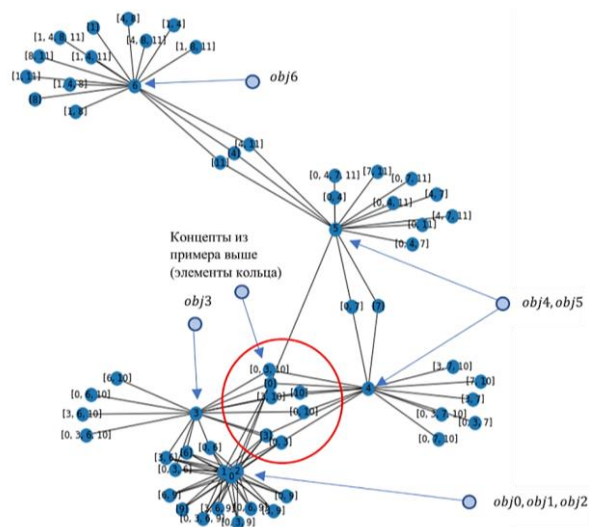


Рис. 3. Граф «объект – атрибут»

Примечание: составлено авторами на основании данных, полученных в исследовании.

Допустим, есть временной ряд $\{x_t\}_{t=0}^T$. Сначала, приведем нормированный ряд в удобный для кластеризации вид. Запишем

ряд как матрицу $\begin{bmatrix} x_0 & \cdots & x_L \\ \vdots & \ddots & \vdots \\ x_{T-L} & \cdots & x_T \end{bmatrix}$, где L – пара-

метр размерности матрицы. Для того, чтобы воспользоваться методами формальных понятий бинаризуем эту матрицу. Для бинаризации установим количество разбиения фазового пространства n и найдем интервалы разбиения. Определим $k_{\min} = \min_{0 \leq t \leq T} x_t$, $k_{\max} = \max_{0 \leq t \leq T} x_t$, тогда I_i (3) – интервал итого разбиения:

$$I_i = \left[k_{\min} + (i-1) \frac{k_{\max} - k_{\min}}{n}, k_{\min} + i \frac{k_{\max} - k_{\min}}{n} \right]. \quad (3)$$

Бинаризация строчки матрицы является булевой операцией. Для каждой компоненты записывается булевой вектор ее попадания во все данные интервалы. Для удобства запишем такую операцию как $F(x) = [\text{bool}(x \in I_1), \dots, \text{bool}(x \in I_n)]$. Тогда строчка булевой матрицы имеет вид $[F(x_j), F(x_{j+1}), \dots, F(x_{j+L})]$. Пример для $n = 3$, $L = 2$, $k_{\min} = -0,0048$, $k_{\max} = 0,004$: $[-0,00024336, 0,00021588, 0,00096167] \rightarrow [0, 1, 0, 0, 1, 0, 0, 1, 0]$. Примером такой матрицы служит рис. 4.

	atr0	atr1	atr2	atr3	atr4	atr5	atr6	atr7	atr8	atr9	atr10	atr11
obj0	1	0	0	1	0	0	1	0	0	1	0	0
obj1	1	0	0	1	0	0	1	0	0	1	0	0
obj2	1	0	0	1	0	0	1	0	0	1	0	0
obj3	1	0	0	1	0	0	1	0	0	0	1	0
obj4	1	0	0	1	0	0	0	1	0	0	1	0
obj5	1	0	0	0	1	0	0	1	0	0	0	1
obj6	0	1	0	0	1	0	0	0	1	0	0	1

Рис. 4. Бинарная матрица

Примечание: составлено авторами на основании данных, полученных в исследовании.

После реконструкции матрицы построим граф «атрибут – объект». Для каждой пары строчек бинарной матрицы найдем все множества кольца ее совпадений значения 1.

Например, строчки *obj3* и *obj4*: $\{atr0, atr3, atr10\}$, $\{atr0, atr3\}$, $\{atr10, atr3\}$, $\{atr0, atr10\}$, $\{atr0\}$, $\{atr3\}$, $\{atr10\}$ (рис. 5).




Рис. 5. Граф «объект – атрибут»

Примечание: составлено авторами на основании данных, полученных в исследовании.

Таким образом, получаем полный алгоритм построения графа «атрибут – объект»:

x_k – вектор, который состоит из бинарных компонент;

L – размерность векторов;
 $E = \{\emptyset\}$ – множество ребер;
 $V = \{x_1, \dots, x_n\}$, где $1, \dots, n$ индексы векторов, которые будут кластеризованы

for v_i in V :
 for v_j in V :
 if $i \neq j$:
 $A = \{ \}$ – порождающее множество кольца
 for k from 1 to L :
 if $v_i[k] = 1$ and $v_j[k] = 1$:
 $A \leftarrow k$
 for m in $\text{Ring}(A)$:
 $m = \text{string}(\text{sorted}(m))$
 $E \leftarrow (v_i, m)$ добавляем ребро
 Получаем $G(E)$ граф «атрибут – объект»

Для нахождения классов используем алгоритм распространения меток (рис. 6). Однако проблема в том, что подграфы в графе, которые являются двудольными или почти двудольными по структуре, приводят к колебаниям меток. Это особенно верно в случаях, когда подграфы имеют форму звездного графа. Следовательно, нужно использовать асинхронное обновление, когда некоторые соседи уже были обновлены в текущей итерации.

ции, а некоторые еще не обновлены в текущей итерации. Тогда алгоритм кластеризации графа будет состоять из следующих шагов:

Пусть:
 G – граф;
 $V = [x_1, \dots, x_n]$ – массив вершин графа;
 $D_V = [\varepsilon(x_1), \dots, \varepsilon(x_n)]$ – массив меток вершин V (на 0 итерации, $\varepsilon(x_i) = i$);
 $w(k, S)$ – количество элементов k в массиве S ;
 $N(x)$ – массив соседей вершины x .
 Тогда:
 while $\forall x \in V \forall u \in N(x) \max_{\varepsilon} \{w(\varepsilon(y), D_{N(x)}) : \forall y \in N(x)\} < w(\varepsilon(u), D_{N(x)})$:
 $\bar{V} = [x_{\sigma(1)}, x_{\sigma(2)}, \dots, x_{\sigma(N)}]$ – массив перестановок вершин в случайном порядке
 for $u \in \bar{V}$:
 $\varepsilon^* = \text{argmax}_{\varepsilon} \{w(\varepsilon(y), D_{N(u)}) : \forall y \in N(u)\}$
 if $\nexists! \varepsilon^*$: выбираем наугад ε^* из множества $\{\varepsilon^*\}$
 $D\{u\} = \varepsilon^*$

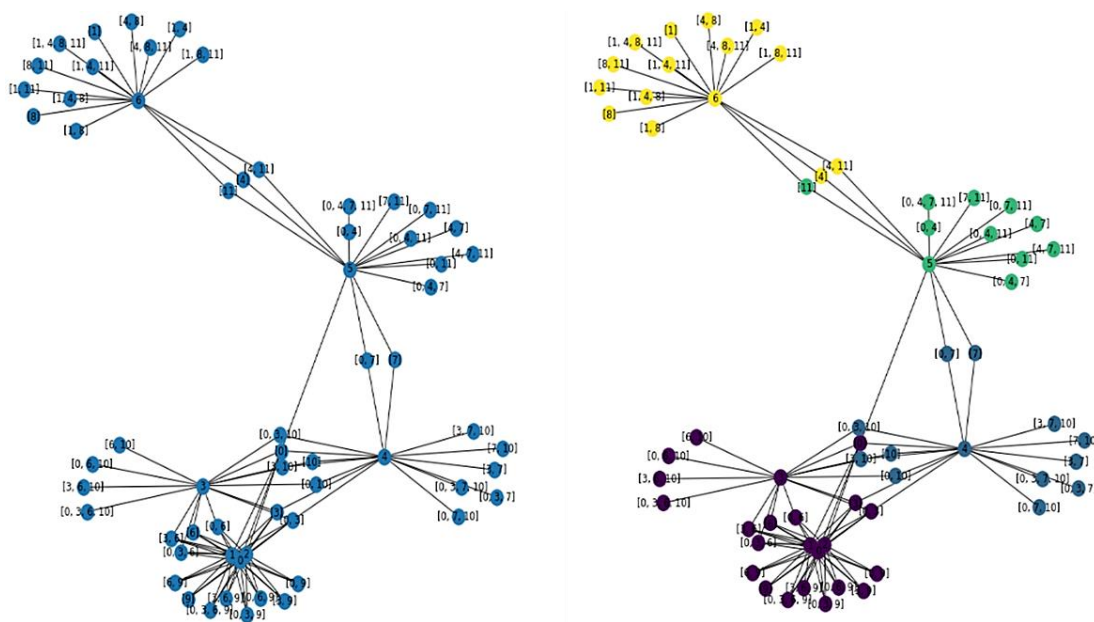


Рис. 6. Кластеризация графа «атрибут – объект»

Видно, что некоторые объекты группируются в один кластер (фиолетовая метка), а другие образуют отличные друг от друга группы (желтая, зеленая, синяя метки)

Примечание: составлено авторами на основании данных, полученных в исследовании.

Характеристики хаотичности, случайности и регулярности в ряде. Определим шумовые кластеры как кластеры с мощностью 1. Если доля вне кластерного шума определяет большинство объектных вершин графа и присутствует много малых кластеров, тогда ряд

можно считать стохастическим. В случае, если пропорция количества кластеров к количеству объектных вершин приближается к 0 и доля шума почти 0, то ряд регулярный. Если количество кластеров большое, а доля шума маленькая (приближается к 0), то ряд

хаотический. Малое количество кластеров и большое количество шума дает нам хаотический-стохастический ряд. Примеры класте-

ризации графа «атрибут – объект» хаотического временного ряда и регулярного изображены на рис. 7.



Рис. 7. Примеры графов хаотического и регулярного ряда

Примечание: составлено авторами на основании данных, полученных в исследовании.

РЕЗУЛЬТАТЫ И ИХ ОБСУЖДЕНИЕ

В численном эксперименте были использованы временные ряды, характеризующие количество новых судебных дел по месяцам в разных регионах России и по разным судебным категориям с 2014-08-01 по 2020-12-01 [11]. Общее число рядов – 3 149. Перед применением вышеописанных алгоритмов все ряды были трансформированы в стационарные; проверка на стационарность осуществлялась с помощью расширенного теста Дики – Фул-

лера [12]. Далее каждый ряд был нормализован для удобства подбора параметров в методах.

Так как многие ряды имеют много константных участков, такие ряды отнесены в отдельную «константную» группу: критерием отнесения является условие $\frac{|[x_i] - \text{mod } a\{x_i\} = 0|}{|\{x_i\}|} > \varepsilon$, где ε – мало. Пример

такого ряда показан на рис. 8. Для предсказания таких рядов использовали среднее по ряду.




Рис. 8. Пример околоконстантного ряда

Примечание: составлено авторами на основании данных, полученных в исследовании.

Остальные ряды были сгруппированы путем (1) вычисления значений энтропии и сложности с последующей кластеризацией и (2) алгоритма, основанного на атрибут-объектном графе.

Фиолетовые точки на плоскости занимают 74,4 % (рис. 9а). «Неконстантных» рядов $\left(\frac{|\{x_i\} - \text{mod } a\{x_i\} = 0|}{|\{x_i\}|} \leq \varepsilon \right)$ для $\varepsilon = 0,33$ было обнаружено порядка 76,3 % (синие точки на рис. 9б). Кластеризация (методом K-means [13])

разбивает плоскость «энтропия – сложность» на четыре основных области (фиолетовая, желтая, зеленая, синяя), где фиолетовая область – стохастические-хаотические ряды 74,4 %, желтая – хаотические 14,5 %, зеленая – хаотические-регулярные 8,1 %, и синие – регулярные 3 % (рис. 9а). Из первого и второго графика (рис. 9) можно предположить, что фиолетовый кластер состоит из неконстантных рядов, которые имеют хаотическую природу с ярко выраженным случайным компонентом.

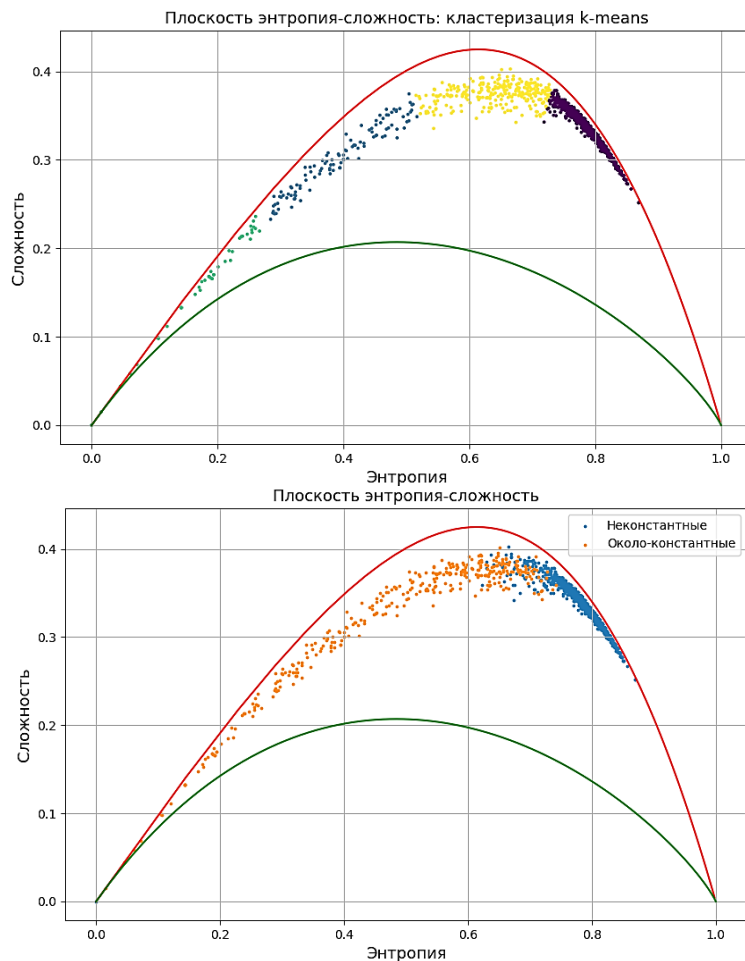


Рис. 9. «Энтропия – сложность»: 9а (верхний) – кластеризация точек на плоскости «энтропия – сложность» с помощью k-means; 9б (нижний) – отображение неконстантных и околоконстантных рядов на плоскости «энтропия – сложность»

Примечание: составлено авторами на основании данных, полученных в исследовании.

Применение метода, основанного на атрибут-объектном графе, дало другое разбиение рассматриваемого множества рядов (рис. 10). Здесь были выделены шумовые и не шумовые кластеры. Распределение процента шумовых

кластеров показало, что у 78 % рядов более 15 % частей последовательности непохожи друг на друга (рис. 10а). К тому же 66 % рядов имеют отношение менее 0,1 количества кластеров на все объекты (рис. 10б).




Рис. 10. Распределение метрик: 10а (левый) – процент шумовых кластеров; 10б (правый) – количество кластеров на объекты

Примечание: составлено авторами на основании данных, полученных в исследовании.

Если рассмотреть ряд как прообраз этих двух подмножеств метрик, такой ряд имеет стохастическую смешанную с хаотической структуру, то есть существуют похожие участки рядов, но есть и части последовательности, непохожие друг на друга. Пересечение

прообразов этих двух подмножеств метрик составляет 73,3 % (рис. 11). Такие ряды относятся к хаотическим-стохастическим рядам. Регулярные ряды составляют 5 % от всех рядов, а строго хаотические, или хаотические-регулярные – 21,7 % (рис. 11).

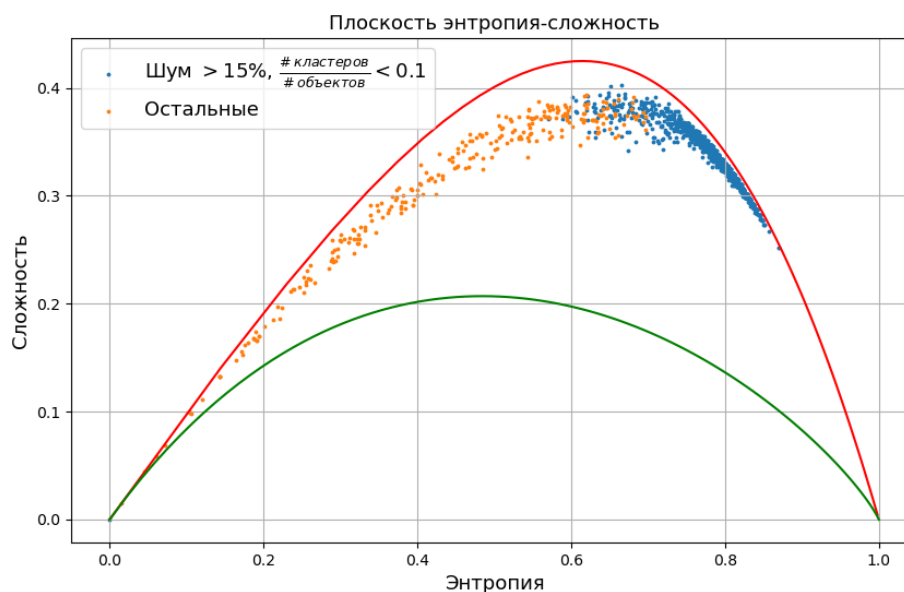


Рис. 11. Распределение около-константных рядов на плоскости «энтропия – сложность»

Примечание: составлено авторами на основании данных, полученных в исследовании.

Приведены примеры рядов, принадлежащих разным структурным группам (рис. 12). На левом верхнем графике доля вне кластерного шума – 1,4 %, а отношение количества кластеров к объектам графа – 0,058, что говорит о регулярности ряда. Правый верхний ряд

имеет 17 % шума и 0,014 пропорцию кластеров к объектам графа, такой ряд является хаотическим-стохастическим. На нижнем – 76 % и 0,073, можно предположить, что ряд чисто стохастический.




Рис. 12. Примеры регулярного, хаотического и хаотического-стохастического рядов
Примечание: составлено авторами на основании данных, полученных в исследовании.

ЗАКЛЮЧЕНИЕ

Проведено исследование характеристик временных рядов, описывающих количество новых дел в суде в разных регионах России и в разных категориях.

Предложено два способа группировки временных рядов: плоскость «энтропия – сложность», граф «атрибут – объект». Установлено, что используя первый метод, процент хаотических-стохастических рядов в выборке составляет 74,4 %, хаотических и хаотических-регулярных – 22,6 %, регулярных – 3 %. Второй метод классифицировал 73,3 % рядов как хаотические-стохастические ряды, 21,7 % –

строго хаотические, или хаотические-регулярные, 5 % – регулярные.

В дальнейшем этот эксперимент поможет решить задачу прогнозирования этих рядов (число дел) на много шагов вперед, так как для разных структур ряда должны быть использованы разные методы прогнозирования. Например, ряды с сильной стохастической разностью разумнее прогнозировать моделями случайных процессов, хаотические ряды – моделями нелинейной динамики, а регулярные – в зависимости от константности ряда (средним или OLS моделями).

Список источников

1. Gromov V. A. Chaotic Time Series Prediction: Run for the Horizon // Proceedings of the 5th International Conference, TMPA 2019, Tbilisi, Georgia, November 7–9, 2019. 2021. P. 29–43.

References

1. Gromov V. A. Chaotic Time Series Prediction: Run for the Horizon // Proceedings of the 5th International Conference, TMPA 2019, Tbilisi, Georgia, November 7–9, 2019. 2021. P. 29–43.

2. Ferré S., Huchard M., Kayoue M., Kuznetsov S. O., Napoli A. Formal Concept Analysis: From Knowledge Discovery to Knowledge Processing // A Guided Tour of Artificial Intelligence Research / Eds. Marquis P., Papini O., Prade H. 2020. P. 411–445.
3. Mehdizadeh S. A Robust Method to Estimate the Largest Lyapunov Exponent of Noisy Signals: A Revision to the Rosenstein's Algorithm // J Biomech. 2019. Vol. 85. P. 84–91.
4. Gottwald G. A., Melbourne I. A New Test for Chaos in Deterministic Systems // Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences. 2004. Vol. 460, No. 2042. P. 603–611.
5. Gottwald G. A., Melbourne I. On the Implementation of the 0–1 Test for Chaos // SIAM Journal on Applied Dynamical Systems. 2009. Vol. 8, Is. 1. P. 129–145.
6. Gottwald G. A., Melbourne I. The 0-1 Test for Chaos: A Review // Chaos Detection and Predictability / Eds. Skokos C., Gottwald G., Laskar J. 2016. P. 221–247.
7. Tempelman J. R., Khasawneh F. A. A Look into Chaos Detection through Topological Data Analysis // Physica D: Nonlinear Phenomena. 2020. Vol. 406. P. 132446.
8. Rosso O. A., Carpi L. C., Saco P. M. et al. Causality and the Entropy–Complexity Plane: Robustness and Missing Ordinal Patterns // Physica A: Statistical Mechanics and its Applications. 2012. Vol. 391, Is. 1–2. P. 42–55.
9. Громов В. А., Мазайшвили К. В., Заикин П. В. и др. Различение хаотических и регулярных временных рядов для идентификации состояния артериовенозной фистулы // Вестник кибернетики. 2022. № 1 (45). С. 72–82.
10. Малинецкий Г. Г., Потапов А. Б., Подлазов А. В. Нелинейная динамика: подходы, результаты, надежды // Синергетика: от прошлого к будущему. 2016. Т. 9, № 28. С. 30–121.
11. Электронное правосудие. URL: <https://kad.arbitr.ru/> (дата обращения: 01.11.2022).
12. Mushtaq R. Augmented Dickey Fuller Test // SSRN Electronic Journal. 2011. 19 p.
13. Liu Y., Ma S., Du X. An Improved K-Means Algorithm Based on a New Cluster Center Selection Method // IEEE Access. URL: https://www.researchgate.net/publication/347610712_An_improved_k-means_algorithm_based_on_a_new_cluster_center_selection_method (дата обращения: 01.11.2022).
2. Ferré S., Huchard M., Kayoue M., Kuznetsov S. O., Napoli A. Formal Concept Analysis: From Knowledge Discovery to Knowledge Processing // A Guided Tour of Artificial Intelligence Research / Eds. Marquis P., Papini O., Prade H. 2020. P. 411–445.
3. Mehdizadeh S. A Robust Method to Estimate the Largest Lyapunov Exponent of Noisy Signals: A Revision to the Rosenstein's Algorithm // J Biomech. 2019. Vol. 85. P. 84–91.
4. Gottwald G. A., Melbourne I. A New Test for Chaos in Deterministic Systems // Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences. 2004. Vol. 460, No. 2042. P. 603–611.
5. Gottwald G. A., Melbourne I. On the Implementation of the 0–1 Test for Chaos // SIAM Journal on Applied Dynamical Systems. 2009. Vol. 8, Is. 1. P. 129–145.
6. Gottwald G. A., Melbourne I. The 0-1 Test for Chaos: A Review // Chaos Detection and Predictability / Eds. Skokos C., Gottwald G., Laskar J. 2016. P. 221–247.
7. Tempelman J. R., Khasawneh F. A. A Look into Chaos Detection through Topological Data Analysis // Physica D: Nonlinear Phenomena. 2020. Vol. 406. P. 132446.
8. Rosso O. A., Carpi L. C., Saco P. M. et al. Causality and the Entropy–Complexity Plane: Robustness and Missing Ordinal Patterns // Physica A: Statistical Mechanics and its Applications. 2012. Vol. 391, Is. 1–2. P. 42–55.
9. Gromov V. A., Mazayshvili K. V., Zaikin P. V. et al. Differentiating Chaotic and Regular Time Series for Identification of Arteriovenous Fistula State // Proceedings in Cybernetics. 2022. No. 1 (45). P. 72–82. (In Russian).
10. Malinetsky G. G., Potapov A. B., Podlazov A. V. Nelineinaia dinamika: podkhody, rezultaty, nadezhdy // Sinergetika: ot proshlogo k budushchemu. 2016. Vol. 9, No. 28. P. 30–121. (In Russian).
11. Elektronnoe pravosudie. URL: <https://kad.arbitr.ru/> (accessed: 01.11.2022). (In Russian).
12. Mushtaq R. Augmented Dickey Fuller Test // SSRN Electronic Journal. 2011. 19 p.
13. Liu Y., Ma S., Du X. An Improved K-Means Algorithm Based on a New Cluster Center Selection Method // IEEE Access. URL: https://www.researchgate.net/publication/347610712_An_improved_k-means_algorithm_based_on_a_new_cluster_center_selection_method (accessed: 01.11.2022).

Информация об авторах

В. А. Громов – доктор физико-математических наук, профессор.

П. П. Лукьянченко – старший преподаватель.

Ю. Н. Бесчастнов – стажер-исследователь.

К. К. Томашук – стажер-исследователь.

Information about the authors

V. A. Gromov – Doctor of Sciences (Physics and Mathematics), Professor.

P. P. Lukyanchenko – Senior Lecturer.

Yu. N. Beschastnov – Research Assistant.

K. K. Tomashchuk – Research Assistant.