

# 1 Индекс УДК

004.852 Статистическое обучение и параметрическое обучение

## 2 Название работы

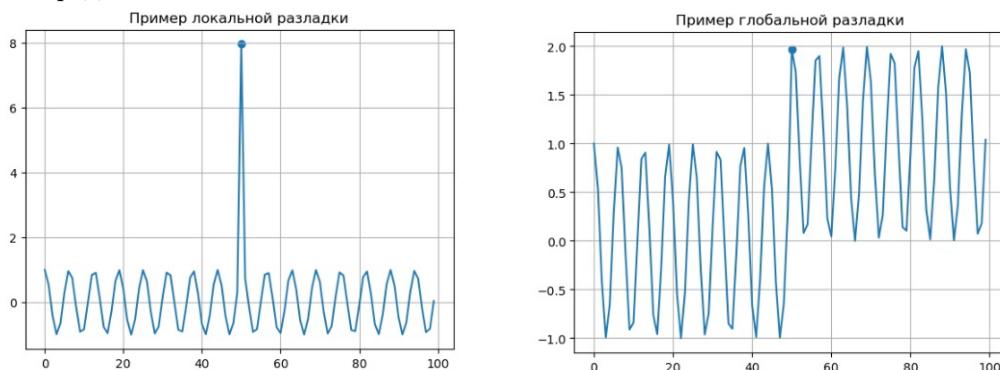
Neural SDE для нахождения моментов разладки временных рядов

## 3 Сведения об авторах

И.Д. Папай, В.В. Стрижов, Э.А. Владимиров – МФТИ

## 4 Тезис

Главной целью данного исследования является проверка фрагмента временного ряда на наличие аномалий.



Точка разладки является моментом локальной разладки, если при игнорировании её природа всего временного ряда в стохастическом плане остается однородной.

Глобальной же, если по достижению оной всё поведение временного ряда резко меняется.

В данной задаче полагая, что временной ряд порождается определенными конечномерными распределениями, приблизим его с помощью стохастических дифференциальных уравнений. Рассматривая фиксированный ди-

пазон, который требуется проверить на наличие аномалий, получим аппроксимацию. Если на определенном шаге решения полученных дифференциальных уравнений и значений временного ряда различаются, то есть происходит резкое их отклонение, то это значит, что в ряду произошла аномалия. Аномалии отсюда и далее мы будем называть точками разладки.

Обыкновенные дифференциальные уравнения (ОДУ) использовались во многих работах [1,2,4,8]. Так, с 2017-го года они были использованы [2] для создания и теоретического обоснования корректности работы модели Neural ODE. Метод ODE был уязвим к состязательным атакам [2]. Модель Neural SDE [2-4] уже строилась на использовании стохастических дифференциальных уравнений (СДУ) и была в этом плане эффективнее своего предшественника.

Ранее [7] модель Neural CDE предлагала использовать стохастический интеграл как решение дифференциального уравнения, характеризующего приращение компонент временного ряда. Neural SDE развила данный концепт, добавив детерминированный коэффициент в дифференциал.

В работах по Neural SDE [2-4], СДУ использовались только для построения доверительных интервалов для элементов временного ряда. Этот подход предлагается развить, используя коэффициенты полученных СДУ. Таким образом, можно будет проверять большие массивы данных на корреляцию между собой. В работе рассматривается задача — найти точки разладки для фиксированного временного ряда. Для каждой из точек временного ряда проверяется decision-rejection критерий о согласованности поведения ряда в ней и всего остального ряда.

Ход решения задачи схож с методами генеративных моделей [12], а не дискриминативными [9,11]. Требуется предъявить читателю не столько новый способ отделить точки разладки, сколько метод оценки вероятности того, что та или иная точка таковой является. Для корректного решения проблемы следует взять лучшее из обоих подходов аналогично тому, как некоторые исследователи уже делали раньше [10].

Продемонстрируем ход алгоритма, описанного в статье, на практике и явно покажем, как осуществляется процесс поиска точек разладки временного ряда.

Эксперимент проводится над выборкой из  $N = 150$  элементов. В каче-

стве тестовой выборки берётся искусственно запшумленный ряд синусов.

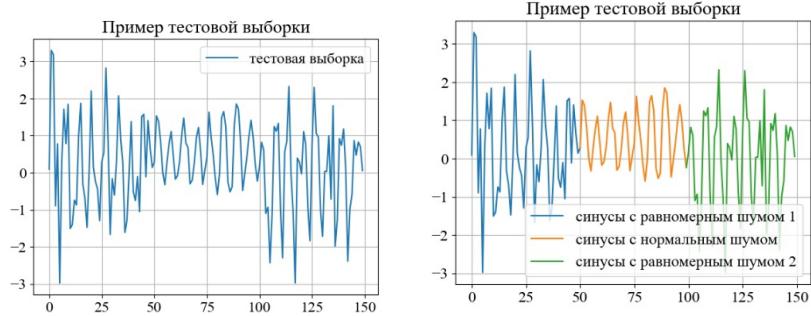
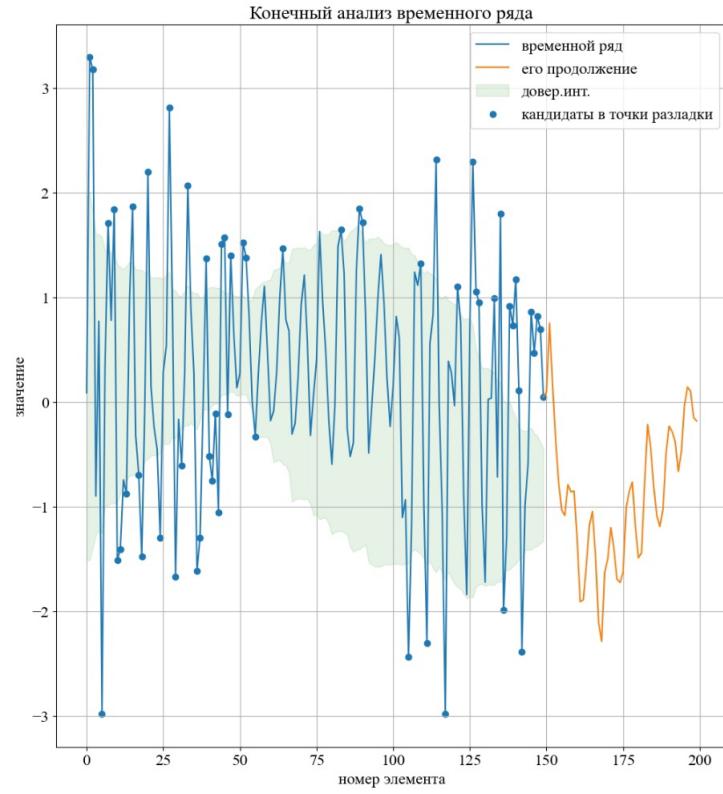


Рис. 1: тестовая выборка

По итогу обучения получаем следующий результат работы алгоритма на исходном временном ряду.



Доверительные интервалы пускай и не точно, но позволяют оценить примерное число точек разладки и место их наибольшего сосредоточения.

Итоговое сравнение с другими методами поисками точек разладки показывает то, что NeuralSDE выигрывает в плане точности, но уступает в плане скорости.

<i>Model</i>	<i>Speed(sec)</i>	<i>Error</i>	
<i>NeuralODE</i>	34.7	0.054	
<i>NeuralCDE</i>	32.5	0.0545	
<i>NeuralSDE</i>	47.2	0.044	
<i>SSA</i>	6.48	0.12	
<i>CuSum</i>	3.56	0.08	
<i>CuSumSqr</i>	20.03	0.061	

## 5 Литература

[1] “Neural Ordinary Differential Equations Ricky” T. Q. Chen, Yulia Rubanova, Jesse Bettencourt, David Duvenaud

[2] “Neural SDE: Stabilizing Neural ODE Networks with Stochastic Noise” Xuanqing Liu, Tesi Xiao, Si Si, Qin Cao, Sanjiv Kumar, Cho-Jui Hsieh

[3] “Riemannian Neural SDE: Learning Stochastic Representations on Manifolds” Sung Woo Park , Hyomin Kim , Kyungjae Lee , Junseok Kwon

[4] “Riemannian Diffusion Models” Chin-Wei Huang, Milad Aghajohari, Avishek Joey Bose, Prakash Panangaden, Aaron Courville

[5] Tian Qi Chen, Yulia Rubanova, Jesse Bettencourt, and David K Duvenaud. Neural ordinary differential equations. In Advances in Neural Information Processing Systems, pages 6572–6583, 2018.

[6] F.Yu. Yaushev, R. V. Isachenko, V. V. Strijov. Concordant models for latent space projections in forecasting, 2020.

[7] Neural Controlled Differential Equations for Irregular Time Series Patrick Kidger, James Morrill, James Foster, Terry Lyons

[8] Neural Ordinary Differential Equations Ricky T. Q. Chen, Yulia Rubanova, Jesse Bettencourt, David Duvenaud

[9] Discriminative models for multi-instance problems with tree-structure Tomas Pevny, Petr Somol

[10] Training Discriminative Models to Evaluate Generative Ones Timothée Lesort, Andrei Stoain, Jean-François Goudou, David Filliat

[11] Discriminative Neural Topic Models Gaurav Pandey, Ambedkar Dukkipati

[12] Deep Generative Modelling: A Comparative Review of VAEs, GANs, Normalizing Flows, Energy-Based and Autoregressive Models Sam Bond-Taylor, Adam Leach, Yang Long, Chris G. Willcocks

[13] Scalable gradients for stochastic differential equations, Li, Xuechen and Wong, Ting-Kam Leonard and Chen, Ricky T. Q. and Duvenaud, David, International Conference on Artificial Intelligence and Statistics, 2020

[14] Neural SDEs as Infinite-Dimensional GANs, Kidger, Patrick and Foster, James and Li, Xuechen and Oberhauser, Harald and Lyons, Terry, International Conference on Machine Learning, 2021