

Available at: <https://cyberleninka.ru/article/n/prognozirovanie-elektricheskoy-nagruzki-energосистемы-na-sleduyushchie-sutki-s-ispolzovaniem-metoda-iskusstvennyh-neyronnyh-setey>.

25. Chernetsov V.I., Kazakovskiy E.N. Prognostirovanie potrebleniya elektricheskoy energii s ispolzovaniem neyronnykh setey [Forecasting the consumption of electrical energy using neural networks], *NiKa* [NiKa], 2006. Available at: <https://cyberleninka.ru/article/n/prognostirovanie-potrebleniya-elektricheskoy-energii-s-ispolzovaniem-neyronnyh-setey>.
26. Jinliang Zhang, Yi-Ming Wei, Dezhi Li, Zhongfu Tan, Jianhua Zhou. Short term electricity load forecasting using a hybrid model, *Energy*, 2018, Vol. 158, pp. 774-781. ISSN 0360-5442, <https://doi.org/10.1016/j.energy.2018.06.012>.
27. Staroverov B.A. Teoreticheskoe obosnovanie i prakticheskaya realizatsiya sistem prognozirovaniya elektropotrebleniya na osnove ansambley neyronnykh setey v masshtabe regional'noy setevoy kompanii [Theoretical justification and practical implementation of electricity consumption forecasting systems based on neural network ensembles on the scale of a regional grid company], 2023. Available at: <https://www.dissercat.com/content/teoreticheskoe-obosnovanie-i-prakticheskaya-realizatsiya-sistem-prognostirovaniya-elektropotr>.

Статью рекомендовал к опубликованию д.т.н., профессор В.В. Курейчик.

Еманов Иван Владимирович – Южный федеральный университет; e-mail: emanov@sfedu.ru; тел.: +79604685348; г. Таганрог; Россия; кафедра вычислительной техники; аспирант.

Сергеев Николай Евгеньевич – e-mail: nesergeev@sfedu.ru; тел.: +79001278025; кафедра вычислительной техники; д.т.н.; доцент; профессор.

Emanov Ivan Vladimirovich – South Federal University; e-mail: emanov@sfedu.ru; phone: +79604685348; Taganrog; Russia; the department of Computer Science; graduate student.

Sergeev Nikolay Evgenievich – e-mail: nesergeev@sfedu.ru; phone: +79001278025; the department of Computer Science; dr. of eng. sc.; assistant professor; professor.

УДК 004.942

DOI 10.18522/2311-3103-2024-4-134-144

Л.Э. Хайруллина, З.Н. Хакимов, Г.З. Хабибуллина

ПРЕДВАРИТЕЛЬНАЯ ВЕЙВЛЕТ-ОБРАБОТКА РЯДОВ ФИНАНСОВЫХ ДАННЫХ В СИСТЕМЕ WOLFRAM MATHEMATICA

Любой временной ряд представляет собой сочетание полезной информации и шумов. Поэтому в анализе финансовых временных рядов одним из ключевых моментов является предварительная обработка данных с целью уменьшения шумовой компоненты. Одним из перспективных способов очистки временного ряда является *трешолдинг* – разложение сигнала на вейвлет-спектр до заданного уровня, обнуление тех вейвлет-коэффициентов разложения, значения которых меньше определенного порогового значения, и последующая вейвлет-реконструкция сигнала по аппроксимирующим и очищенным на каждом уровне детализирующим коэффициентам. *Трешолдинг* проводится с применением современных программных средств, среди которых исследователи чаще всего отдают предпочтение среде *Matlab*. В данной работе представлена демонстрация возможностей системы компьютерной математики *Wolfram Mathematica* в предварительной обработке финансовых данных. *Wolfram Mathematica* обладает мощным функционалом, позволяющим проводить качественную обработку временных рядов. Система содержит большую коллекцию семейств вейвлетов, множественные варианты дискретных и непрерывных вейвлет-преобразований. В качестве объекта исследования была выбрана история ежедневных котировок акций Сбербанка за последние 3 года. Анализ полученных результатов показал, что на качество очистки сигнала влияет выбор базисного вейвлета – в нашем случае предпочтительным оказалось использование вейвлета Добеши 6-го порядка. Максимальное отношение сигнал/шум достигается при жесткой пороговой обработке с порогом «SURELevel». Проведенные исследования показали, что вейвлет-трешолдинг над детализирующими коэффициентами вейвлет-разложения является эффективным методом подавления выбросов и флуктуаций временного ряда. Очищенный сигнал повторяет форму исходного сигнала, все пики хорошо выражены. При этом в краткосрочном прогнозе получаются более точные прогнозные значения.

Финансовый временной ряд; шум; *трешолдинг*; пороговая обработка; вейвлет-анализ; вейвлет Добеши; *Wolfram Mathematica*.

L.E. Khairullina, Z.N. Khakimov, G.Z. Khabibullina

**PRELIMINARY WAVELET PROCESSING OF FINANCIAL DATA SERIES
IN THE WOLFRAM MATHEMATICA SYSTEM**

Any time series is a combination of useful information and noise. Therefore, in the analysis of financial time series, one of the key points is the preprocessing of data in order to reduce the noise component. One of the promising ways to clean up the time series is threading – decomposing the signal into a wavelet spectrum to a given level, zeroing out those wavelet decomposition coefficients whose values are less than a certain threshold value, and subsequent wavelet reconstruction of the signal using approximating and refined detailing coefficients at each level. Thresholding is carried out using modern software tools, among which researchers most often prefer the Matlab environment. This paper presents a demonstration of the capabilities of the Wolfram Mathematica computer mathematics system in the preliminary processing of financial data. Wolfram Mathematica has powerful functionality that allows high-quality processing of time series. The system contains a large collection of wavelet families, multiple variants of discrete and continuous wavelet transformations. The history of Sberbank's daily stock quotes over the past 3 years was chosen as the object of the study. An analysis of the results showed that the quality of signal purification is influenced by the choice of a basic wavelet – in our case, the use of a 6th-order Daubechies wavelet turned out to be preferable. The maximum signal-to-noise ratio is achieved with rigid threshold processing with a "SURELevel" threshold. The conducted studies have shown that wavelet thresholding over the detailing coefficients of the wavelet decomposition is an effective method of suppressing outliers and fluctuations of the time series. The cleared signal repeats the shape of the original signal, all peaks are well expressed. At the same time, more accurate forecast values are obtained in the short-term forecast

Financial time series; noise; thresholding; threshold processing; wavelet analysis; Daubechies wavelet; Wolfram Mathematica.

Введение. Анализ временных рядов финансовых данных является сложной задачей из-за их нелинейности и нестационарности. Нестационарность выражается в изменчивости статистических характеристик ряда (математического ожидания, дисперсии) с течением времени и проявляется в виде тренда, цикличности, сезонности, случайном блуждании или их сочетании. Нестационарные сигналы чаще всего состоят из кратковременных высокочастотных и длительных низкочастотных компонентов, поэтому для анализа таких сигналов предпочтительнее использовать вейвлет-анализ [1]. He&Nguen [2] выделяют следующие особенности вейвлет-анализа применительно к временным рядам: 1) для вейвлет-анализа не требуется предположения о стационарности данных, 2) информация предоставляется как во временной, так и в частотной области, 3) вейвлет-анализ дает возможность находить разрывы и сдвиги в рядах данных. Подробный обзор возможностей дискретного вейвлет-анализа приведен в работе Chaovalit P., Gangopadhyay A. и др. [3]. В ней авторы систематизировали научные работы по применению вейвлет-анализа в разных областях, привели примеры прикладного применения этого математического аппарата и указали возможные будущие направления развития этой области.

Любой временной ряд представляет собой сочетание полезной информации и шумов. Значительный ряд работ посвящены описанию методов и технологий очистки временного ряда от шумов. Так, в коллективной работе Кропотова Ю.А. с соавторами [4] разработана математическая модель фильтрации шумов на основе пороговой обработки детализирующих коэффициентов вейвлет-разложения. Тем самым авторы добиваются увеличения отношения сигнал/шум и, соответственно, повышения точности представления данных в восстановленном ряду. В статье Белова А.А. [5] проведен анализ критериев при выборе пороговых уровней вейвлет-преобразования для сглаживания рядов данных. В работе Тараненко У.К. [6] предложен алгоритм, позволяющий определить наиболее эффективные методы дискретной вейвлет-фильтрации в зависимости от характера измеряемого сигнала.

Отфильтровывая шум, аналитики могут улучшить прогнозирующую силу своих моделей. В коллективной работе Shaikh W. и др. [7] алгоритм вейвлет-декомпозиции объединен с различными традиционными моделями прогнозирования временных рядов, такими как метод опорных векторов, регрессионные модели, нейронные сети. Авторы де-

лают вывод, что такое комбинирование дает возможность получить лучшие прогнозные значения. Аналогичный вывод постулируется и в работе Lee H. [8] – вейвлет-анализ является эффективным инструментом снижения уровня шума при анализе финансовых временных рядов и последующем прогнозировании с помощью модели ARIMA. В статьях Benrhmach G. и др. [9], Boubaker H. и др. [10] разработаны гибридные методы моделирования финансового временного ряда, основанные на дискретном вейвлет-разложении ряда и дальнейшем применении искусственных нейронных сетей. Предобработка временных финансовых рядов состояния фондового рынка с помощью непрерывного вейвлет-преобразования и дальнейший анализ с помощью сверточных нейронных сетей изучается в работе Du B. и Вагусса Р. [11].

Чаще всего при проведении вейвлет-анализа исследователями используется система Matlab, языки программирования R или Python (см., напр., [12–14]). В настоящее время актуальной научной теоретической и практической задачей является поиск новых программно-аппаратных средств, позволяющих быстро и качественно проводить сложные вычисления. Одним из лидеров среди существующих программных продуктов является Wolfram Mathematica. К преимуществам применения данной системы относится и то, что благодаря возможности облачных вычислений (WolframCloud) пользователь становится слабозависимым от аппаратного обеспечения. Данная статья имеет своей целью демонстрацию предварительной обработки временного ряда финансовых данных с помощью вейвлет-анализа в системе компьютерной математики Wolfram Mathematica.

Вейвлет-анализ и пороговая обработка сигнала. Слово «wavelet» буквально означает «маленькая волна». Вейвлеты – это семейство локальных по времени и частоте функций. Все функции семейства получаются из одного вейвлета посредством его сдвига и растяжений. При анализе экономических данных в основном используются дискретные вейвлеты, обеспечивающие более удобную декомпозицию и реконструкцию сигналов.

Дискретное вейвлет-преобразование сигнала $f(t)$ состоит в его разложении в ряд [14]:

$$f(t) = c_0 \psi(t) + \sum_{j=1}^N \sum_{k=0}^{2^j-1} c_{jk} \varphi_{jk}(t),$$

где $\psi(t)$ – называют отцовским вейвлетом, $\varphi_{jk}(t)$ – функции, полученные из материнского вейвлета $\varphi(t)$ путем сжатия и сдвига. Эти функции удовлетворяют условиям

$$\int_{-\infty}^{+\infty} \varphi(t) dt = 1, \quad \int_{-\infty}^{+\infty} \psi(t) dt = 0.$$

Согласно теории многоуровневой аппроксимации сигналов, построенной Mallat [15], любой сигнал можно представить в виде суммы аппроксимирующего и детализирующих сигналов. В общем виде разложение сигнала до j -го уровня декомпозиции может быть представлено соотношением:

$$f(t) = A_j(t) + \sum_{m=1}^j D_m(t) = \sum_{k \in Z} a_{jk} \varphi_{jk}(t) + \sum_{k \in Z} d_{mk} \psi_{mk}(t),$$

где $a_{jk} = (f(t), \varphi_{jk}(t))$ и $d_{mk} = (f(t), \psi_{mk}(t))$ – аппроксимирующие и детализирующие коэффициенты, а базисные функции φ и ψ , соответственно, равны:

$$\varphi(t) = 2 \sum_l L(l) \varphi(2t-l), \quad L(l) = (\varphi(t), \varphi(2t-l)),$$

$$\psi(t) = 2 \sum_l H(l) \varphi(2t-l), \quad H(l) = (\psi(t), \varphi(2t-l)), \quad l=2n-1.$$

Коэффициенты аппроксимации содержат полезную информацию о поведении сигнала (грубое приближение сигнала). Коэффициенты детализации на каждом уровне разложения содержат уточняющую информацию о сигнале. В этих же коэффициентах могут содержаться шумы – случайные колебания данных, не подчиняющиеся определенным закономерностям. Они не несут полезной информации о главных тенденциях временного ряда данных и могут исказить интерпретацию сигнала. Поэтому анализ временных рядов

целесообразно предварять очисткой от шумов. Как правило, шумовые компоненты имеют меньшую амплитуду по сравнению с основным сигналом. В связи с этим одним из способов удаления шумов является трешолдинг - разложение сигнала на вейвлет-спектр до заданного уровня, обнуление тех вейвлет-коэффициентов разложения, значения которых меньше определенного порогового значения, и последующая вейвлет-реконструкция сигнала по аппроксимирующим и очищенным на каждом уровне детализирующим коэффициентам [4-5, 16-17].

Существуют разные виды пороговой обработки сигнала, из которых выделяют мягкий и жесткий. Жесткий трешолдинг предполагает обнуление всех коэффициентов, меньших заданного порога, остальные коэффициенты сохраняются неизменными:

$$x = \begin{cases} 0, & |x| \leq \delta, \\ x, & |x| > \delta. \end{cases}$$

Мягкий трешолдинг дополнительно предполагает уменьшение по модулю всех остальных коэффициентов на величину порога:

$$x = \begin{cases} 0, & |x| \leq \delta, \\ \text{sgn}(x) (|x| - \delta), & |x| > \delta. \end{cases}$$

Порог может быть единым для всех коэффициентов и уровней разложения или различным в зависимости от частотных особенностей сигнала. От выбора порогового уровня зависит качество сглаживания сигнала – слишком малый порог не устранил шумы, слишком большой может привести к потере коэффициентов, содержащих существенную информацию о сигнале [5].

В качестве пороговых значений используются:

- ♦ порог на основе алгоритма Штейна несмещенной оценки риска:

$$\delta = \arg \min \sum_{i=1}^N (\bar{d}_{ji} - d_{ji})^2,$$

где $\bar{d}_{ji}$ и d_{ji} , соответственно, эмпирические и истинные коэффициенты детализации сигнала,

- ♦ порог Донохо-Джонстона $\delta = \sigma \sqrt{2 \ln N}$, где

$$\sigma = \frac{\text{median} \left\{ |x|, k=0, \frac{N}{2} - 1 \right\}}{0,6745}$$

- ♦ порог на основе минимаксной оценки

$$\delta = \begin{cases} \sigma (0,3936 + 0,1829 \log_2 N), & N > 32 \\ 0, & N < 32 \end{cases}$$

$$\sigma = \frac{\text{median} \{ |x| \}}{0,6745}$$

и некоторые другие.

Инструменты вейвлет-обработки в Wolfram Mathematica. В данной работе математическая обработка финансового временного ряда осуществляется с помощью системы компьютерной математики Wolfram Mathematica, обладающего мощной вычислительной и визуализирующей базой. Язык Wolfram Language обеспечивает полнофункциональную реализацию вейвлет-анализа [18].

Дискретное вейвлет-преобразование реализуется с помощью функции

`DiscreteWaveletTransform[]`.

По умолчанию применяется вейвлет Хаара. В качестве материнского вейвлета в зависимости от характерных особенностей сигнала можно использовать вейвлеты:

`DaubeshiesWavelet[], SymletWavelet[],`

`BiorthogonalSplineWavelet[]`, `CoifletWavelet[]` и др.

Восстановление сигнала осуществляется с помощью функции

`InverseWaveletTransform[]`.

Для пороговой очистки используется функция `WaveletThreshold`:

`WaveletThreshold[dwd, tspec, wind]`,

где *dwd* – коэффициенты дискретного вейвлет-преобразования, *tspec* – характеристика порога, *wind* – индексы вейвлет-коэффициентов, к которым будет применяться пороговая обработка.

В качестве характеристики порога можно выбрать встроенные:

- ◆ `Hard` (жесткая обработка с порогом δ),
- ◆ `Soft` (мягкая обработка с порогом δ)

и некоторые другие.

Пороговое значение δ также можно выбрать из имеющихся, например:

- ◆ `"SURE"` – несмещенная оценка риска Штейна;
- ◆ `"SURELevel"` – порог `"SURE"`, применяемый для каждого уровня разложения сигнала;
- ◆ `"Universal"` – порог Донохо-Джонстона;
- ◆ `"SUREHybrid"` – комбинация порогового значения `"SURE"` и `"Universal"`;
- ◆ `"UniversalLevel"` – порог `"Universal"`, применяемый для каждого уровня разложения сигнала, и другие.

Эмпирическое исследование. В качестве объекта исследования выберем историю котировок акций Сбербанка за период с 1.01.2020 по 30.04.2024, в качестве единицы исследования примем ежедневные торги. Фурье-спектр этого ряда наглядно демонстрирует наличие высокочастотных шумов (рис. 1):




Рис. 1. Фурье-спектр сигнала

Проверка на стационарность данного временного ряда тестом Дики-Фулера подтверждает его нестационарность:

```
H = UnitRootTest[dat, Automatic, "HypothesisTestData"];
[ "TestDataTable", "DickeyFullerF"]
```

	Statistic	P-Value
Dickey-Fuller F	-0.0120161	0.679958

Для очистки сигнала от шума будем использовать ортогональные вейвлеты, обладающие возможностью быстрого разложения и реконструкции сигнала. Эффективность процедуры очистки сигнала в значительной степени зависит от вейвлет-базиса. Следуя [19–20], для выбора оптимального вейвлета будем использовать критерий минимума энтропий. Для этого рассчитаем энергию динамического ряда на каждом масштабе j :

$$E_j = \sum_k d_{j,k}^2$$

и найдем энтропию набора энергий:

$$WE = - \sum_{j=1}^N p_j \ln(p_j),$$

где $p_j = \frac{E_j}{\sum_{j=1}^N E_j}$ – относительная вейвлет-энергия, демонстрирующая распределение

вейвлет-энергии по уровням разложения, N – максимальный уровень разложения. В качестве наилучшей выберем ту вейвлет-функцию, которой будет соответствовать наименьшая энтропия.

Для расчета вейвлет-энтропии использовалась опция EnergyFraction функции DiscreteWaveletTransform системы Wolfram Mathematica:

```
dwd = DiscreteWaveletTransform[dat, DaubechiesWavelet[4], 4]
efrac = dwd["EnergyFraction"];
ED4 = -Sum[efrac[[i, 2]] Log[efrac[[i, 2]]], {i, 1, Length[efrac]}
```

Энтропия рассчитывалась для вейвлетов Хаара, Мейера, Добеши и Симлета разных порядков. Разложение исходного сигнала возможно до 10 уровня. Однако исходя из того, что высшие уровни сигнала содержат лишь малую часть информации о сигнале, мы ограничились декомпозицией до 4 уровня. Анализ вейвлет-энтропий показал, что наиболее предпочтительным является использование вейвлета Добеши 6-го порядка (рис. 2), который можно рассматривать как компромисс между длиной области задания и регулярности базисной функции. Именно этот вейвлет был использован в дальнейших расчетах.




Рис. 2 Изменение вейвлет-энтропии в зависимости от вейвлет-базиса

На рис. 3 показано дерево последовательного разложения выбранного финансового ряда вейвлетом Добеши 6-го порядка на аппроксимирующие (a_i) и детализирующие (d_i) коэффициенты.




Рис. 3. Дерево разложения временного ряда

Очистка от шумов проводилась по детализирующим коэффициентам. В качестве порогового значения использовалась встроенная несмещенная оценка риска Штейна, порог Донохо-Джонстона и их модификации и комбинации. В Wolfram Mathematica очистка сигнала реализуется командами:

```
dwt = DiscreteWaveletTransform[dat, DaubechiesWavelet[6], 4]
WT = WaveletThreshold[dwt, {"Hard", "SURE"}];
WT["ThresholdTable"]
datthr = InverseWaveletTransform[WT];
```

С помощью опции ThresholdTable функции WaveletThreshold можно вывести пороговые значения очистки на каждом уровне разложения (табл.1).

Качество очистки оценивалось с помощью отношения сигнал/шум, определяемого формулой:

$$SNR = 10 \lg \frac{\sigma_{\text{восст}}^2}{\sigma_{\text{шум}}^2},$$

где $\sigma_{\text{восст}}^2$ – дисперсия восстановленного сигнала $\sigma_{\text{шум}}^2$ – дисперсия шума.

Таблица 1

Результаты пороговой очистки вейвлетом Добеши 6 порядка

Порог	Шумовой порог на каждом уровне разложения	SNR при пороговой обработке «Hard»	SNR при пороговой обработке «Soft»
"SURE"	1) 0,443732 2) 0,443732 3) 0,443732 4) 0,443732	56,822	44,286
"SURELevel"	1) 0,443732 2) 0,340379 3) 0,007522 4) 0,213248	57,492	45,849
"Universal"	1) 7,43896 2) 7,43896 3) 7,43896 4) 7,43896	28,274	25,509
"SUREHybrid"	1) 0,443732 2) 0,443732 3) 0,443732 4) 0,443732	56,822	44,286
"UniversalLevel"	1) 7,06539 2) 11,9341 3) 19,9674 4) 53,8596	22,037	20,812

Как видим, наибольшее отношение сигнал/шум получено при жесткой пороговой обработке адаптивным порогом «SURELevel». На рис. 4 продемонстрирован сигнал после шумоподавления – трешолдинг позволил избавиться от шумов и при этом не исказил основную информацию по сигналу.




Рис. 4. Графики исходного и очищенного от шумов временного ряда

Очищенный временной ряд котировок применим для прогноза. Используя критерий Акаике, была подобрана оптимальная модель ARMA для исходных и очищенных данных и построен прогноз на 4 шага вперед (табл. 2):

```
TimeSeriesModelFit[dat, "ARMA"] ["CandidateSelectionTable"];
tsm=TimeSeriesModelFit[dat, "ARMA"] // Normal;
forecast[tsm];
forecast["Path"]
```

Таблица 2

Прогнозные значения

Точные значения, май 2024	Прогноз по очищенным от шума данным	Прогноз по исходному временному ряду
307,37	307,767	308,072
307,53	307,472	307,835
306,01	307,273	307,633
308,22	307,075	307,432

Как видим, в краткосрочном прогнозе по очищенному ряду получаются более точные значения.

Выводы. Система Wolfram Mathematica обладает мощным функционалом, позволяющим проводить качественную обработку временных рядов. Анализ полученных результатов показал, что на качество очистки сигнала влияет выбор базисного вейвлета – в нашем случае предпочтительным оказалось использование вейвлета Добеши 6-го порядка. Максимальное отношение сигнал/шум достигается при жесткой пороговой обработке с порогом «SURELevel». Проведенные исследования показали, что вейвлет-трешолдинг над детализирующими коэффициентами вейвлет-разложения является эффективным методом подавления выбросов и флуктуаций временного ряда. Очищенный сигнал повторяет форму исходного сигнала, все пики хорошо выражены. При этом в краткосрочном прогнозе получаются более точные прогнозные значения.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. *Daubechies I.* The wavelet transform, time-frequency localization and signal analysis // IEEE transactions on information theory. – 1990. – 36 (5). – P. 961-1005.
2. *He T., Nguyen T.* Wavelet Analysis and Applications in Economics and Finance // Scholarship. – 2015. – 26. – URL: <https://www.royj.com/open-access/wavelet-analysis-and-applications-in-economics-and-finance.php?aid=62323&view=mobile>.
3. *Chaovalit P., Gangopadhyay A., Karabatis G. and Chen Z.* Discrete wavelet transform-based time series analysis and mining // ACM Comput. Surv. – 2011. – 43, 2, Article 6. – 37 p. – URL: <https://doi.acm.org/10.1145/1883612.1883613>.

4. Кротов Ю.А., Белов А.А., Проскуряков А.Ю. Обработка временных рядов с применением вейвлет-преобразований для повышения точности представления информации // Транспортное машиностроение. – 2018. – № 8 (69). – URL: <https://cyberleninka.ru/article/n/obrabotka-vremennyh-ryadov-s-primeneniem-veyvlet-preobrazovaniy-dlya-povysheniya-tochnosti-predstavleniya-informatsii> (дата обращения: 22.04.2024).
5. Белов А.А., Проскуряков А.Ю. Сглаживание временных рядов на основе вейвлет-преобразования в системах автоматизированного экологического мониторинга // Методы и устройства передачи и обработки информации. – 2010. – № 1 (12). – С. 21-24.
6. Taranenko Y.K. Methods of Discrete Wavelet Filtering of Measurement Signals: an Algorithm for Choosing a Method // Meas Tech. – 2022. – 64. – P. 801-808. – <https://doi.org/10.1007/s11018-022-02007-6>.
7. Shaikh W., Syed F., Pandhiani S. & Solangi M. Wavelet Decomposition Impacts on Traditional Forecasting Time Series Models // Computer Modeling in Engineering & Sciences. – 2022. – Vol. 130. – P. 1517-1532. – DOI: 10.32604/cmescs.2022.017822.
8. Lee H.Y., Beh W.L. & Lem K.H. Wavelet as a Viable Alternative for Time Series Forecasting // Austrian Journal of Statistics. – 2020. – 49. – P. 38-47.
9. Benrhmach G., Namir K., Bouyaghroumni J. & Namir A. Financial time series prediction using wavelet and artificial neural network. – 2021. – Vol 11, No. 5. – P. 5487-5500. – 10.28919/jmcs/5978.
10. Boubaker H., Canarella G., Gupta R. et al. A Hybrid ARFIMA Wavelet Artificial Neural Network Model for DJIA Index Forecasting // Comput. – 2023. – Econ 62. – P. 1801-1843. – <https://doi.org/10.1007/s10614-022-10320-z>.
11. Du B., Barucca P. Image Processing Tools for Financial Time Series Classification. – <https://doi.org/10.48550/arXiv.2008.06042>. – 2020.
12. Lee G., Gommers R., Waselewski F., Wohlfahrt K. & Aaron PyWavelets: A Python package for wavelet analysis // Journal of Open Source Software. – 2019. – 4. 1237. – 10.21105/joss.01237.
13. Манонина И.В. Обработка детализирующих вейвлет-коэффициентов для повышения точности рефлектометрических измерений // Научный вестник МГТУ ГА. – 2016. – № 5. – URL: <https://cyberleninka.ru/article/n/obrabotka-detaliziruyushih-veyvlet-koeffitsientov-dlya-povysheniya-tochnosti-reflektometricheskih-izmereniy> (дата обращения: 22.04.2024).
14. Дьяконов В.П. Вейвлеты. От теории к практике. – 2-е изд., перераб. и доп. – М.: СОЛОН-Пресс, 2010. – 400 с.
15. Mallat S.G. A Theory For Multiresolution Signal Decomposition: The Wavelet Representation // IEEE Transactions on Pattern Analysis and Machine Intelligence. – 1989. – No. 11. – P. 674-693.
16. Московский С.Б., Сергеев А.Н., Лалина Н.А. Очистка сигнала от шумов с использованием вейвлет-преобразования // Universum: Технические науки. – 2015. – № 2 (15). – URL: <http://7universum.com/ru/tech/archive/item/1958>.
17. Московский С.Б., Сергеев А.Н., Сидорова Е.И., Марудов А.А. Методы вейвлет-анализа в задачах обработки экспериментальных данных // EESJ. – 2019. – No. 4-4 (44). – URL: <https://cyberleninka.ru/article/n/metody-veyvlet-analiza-v-zadachah-obrabotki-eksperimentalnyh-dannyh>.
18. Wavelet Analysis. – URL: <https://reference.wolfram.com/language/guide/Wavelets.html>.
19. Krotkikh S., Kirichenko L. Analysis of event-related potentials of eeg signal using discrete wavelet transform // Radio Electronics, Computer Science, Control. – 2012. – 10.15588/1607-3274-2011-2-15.
20. Мифтахова М.Э., Панасюк М.В. Вейвлет-анализ динамики региональной социально-экономической системы // Ученые записки Казанского государственного университета. Серия «Естественные науки». – 2009. – Т. 151. – Вып. 1. – С. 247-262.

REFERENCES

1. Daubechies I. The wavelet transform, time-frequency localization and signal analysis, *IEEE transactions on information theory*, 1990, 36 (5), pp. 961-1005.
2. He T., Nguyen T. Wavelet Analysis and Applications in Economics and Finance, *Scholarship*, 2015, 26. Available at <https://www.rroij.com/open-access/wavelet-analysis-and-applications-in-economics-and-finance.php?aid=62323&view=mobile>.
3. Chaovalit P., Gangopadhyay A., Karabatis G. and Chen Z. Discrete wavelet transform-based time series analysis and mining, *ACM Comput. Surv.*, 2011, 43, 2, Article 6, 37 p. Available at: doi.org/10.1145/1883612.1883613.
4. Кротов Ю.А., Белов А.А., Проскуряков А.Ю. Обработка временных рядов с применением вейвлет-преобразований для повышения точности представления информации [Processing of time series using wavelet transforms to improve the accuracy of information presentation], *Transportnoe mashinostroyeniye* [transport engineering], 2018, No. 8 (69). Available at: <https://cyberleninka.ru/article/n/obrabotka-vremennyh-ryadov-s-primeneniem-veyvlet-preobrazovaniy-dlya-povysheniya-tochnosti-predstavleniya-informatsii> (accessed 22 April 2024).

5. Belov A.A., Proskuryakov A.Yu. Sglazhivanie vremennykh ryadov na osnove veyvlet-preobrazovaniya v sistemakh avtomatizirovannogo ekologicheskogo monitoringa [Smoothing of time series based on wavelet transform in automated environmental monitoring systems], *Metody i ustroystva peredachi i obrabotki informatsii* [Methods and devices for information transmission and processing], 2010, No. 1 (12), pp. 21-24.
6. Taranenko Y.K. Methods of Discrete Wavelet Filtering of Measurement Signals: an Algorithm for Choosing a Method, *Meas Tech.*, 2022, 64, pp. 801-808. Available at: <https://doi.org/10.1007/s11018-022-02007-6>.
7. Shaikh W., Syed F., Pandhiani S. & Solangi M. Wavelet Decomposition Impacts on Traditional Forecasting Time Series Models, *Computer Modeling in Engineering & Sciences*, 2022, Vol. 130, pp. 1517-1532. DOI: 10.32604/cmescs.2022.017822.
8. Lee H.Y., Beh W.L. & Lem K.H. Wavelet as a Viable Alternative for Time Series Forecasting, *Austrian Journal of Statistics*, 2020, 49, pp. 38-47.
9. Benrhmach G., Namir K., Bouyaghroumni J. & Namir A. Financial time series prediction using wavelet and artificial neural network // *Journal of Mathematical and Computational Science*, 2021, Vol. 11, No. 5, pp. 5487-5500. 10.28919/jmcs/5978.
10. Boubaker H., Canarella G., Gupta R. et al. A Hybrid ARFIMA Wavelet Artificial Neural Network Model for DJIA Index Forecasting, *Comput.*, 2023, Econ 62, pp. 1801-1843. Available at: <https://doi.org/10.1007/s10614-022-10320-z>.
11. Du B., Barucca P. Image Processing Tools for Financial Time Series Classification. Available at: <https://doi.org/10.48550/arXiv.2008.06042>, 2020.
12. Lee G., Gommers R., Waselewski F., Wohlfahrt K. & Aaron PyWavelets: A Python package for wavelet analysis, *Journal of Open Source Software*, 2019, 4, 1237. 10.21105/joss.01237.
13. Manonina I.V. Obrabotka detaliziruyushchikh veyvlet-koeffitsientov dlya povysheniya tochnosti reflektometricheskikh izmereniy [Processing of detailing wavelet coefficients to improve the accuracy of reflectometric measurements], *Nauchnyy vestnik MGTU GA* [Scientific Bulletin of MSTU GA], 2016, No. 5. Available at: <https://cyberleninka.ru/article/n/obrabotka-detaliziruyushchih-veyvlet-koeffitsientov-dlya-povysheniya-tochnosti-reflektometricheskikh-izmereniy> (accessed 22 April 2024).
14. D'yakonov V.P. Veyvlety. Ot teorii k praktike [Wavelets. From theory to practice]. 2nd ed. Moscow: SOLON-Press, 2010, 400 p.
15. Mallat S.G. A Theory For Multiresolution Signal Decomposition: The Wavelet Representation, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1989, No. 11, pp. 674-693.
16. Moskovskiy S.B., Sergeev A.N., Lalina N.A. Ochistka signala ot shumov s ispol'zovaniem veyvlet-preobrazovaniya [Signal cleaning from noise using wavelet transform], *Universum: Tekhnicheskie nauki* [Universum: Technical sciences], 2015, No. 2 (15). Available at: <http://7universum.com/ru/tech/archive/item/1958>.
17. Moskovskiy S.B., Sergeev A.N., Sidorova E.I., Marudov A.A. Metody veyvlet-analiza v zadachakh obrabotki eksperimental'nykh dannykh [Wavelet Analysis Methods in Experimental Data Processing Problems], *EESJ*, 2019, No. 4-4 (44). Available at: <https://cyberleninka.ru/article/n/metody-veyvlet-analiza-v-zadachah-obrabotki-eksperimentalnykh-dannykh>.
18. Wavelet Analysis. Available at: <https://reference.wolfram.com/language/guide/Wavelets.html>.
19. Krotkikh S., Kirichenko L. Analysis of event-related potentials of eeg signal using discrete wavelet transform, *Radio Electronics, Computer Science, Control*, 2012. 10.15588/1607-3274-2011-2-15.
20. Miftakhova M.E., Panasyuk M.V. Veyvlet-analiz dinamiki regional'noy sotsial'no-ekonomicheskoy sistemy [Wavelet analysis of the dynamics of a regional socio-economic system], *Uchenye zapiski Kazanskogo gosudarstvennogo universiteta. Seriya «Estestvennye nauki»* [Scientific notes of Kazan State University. Series "Natural sciences"], 2009, Vol. 151, Issue 1, pp. 247-262.

Статью рекомендовал к опубликованию д.т.н., профессор А.В. Боженюк.

Хайруллина Лилия Эмировна – Казанский федеральный университет; e-mail: lxayrullina@yandex.ru; Казань, Россия; тел.: +79272464003; кафедра информационных систем; к.ф.-м.н.; доцент.

Хакимов Зульфат Ниязович – e-mail: znkhakimov@stud.kpfu.ru; аспирант.

Хабибуллина Гузель Забировна – e-mail: hg21980@rambler.ru; тел.: +79274057021; кафедра теории относительности и гравитации; к.пед.н.; доцент.

Khairullina Lilia Emitovna – Kazan Federal University; e-mail: lxayrullina@yandex.ru; Kazan, Russia; phone: +79272464003; the Department of Information Systems; cand. of phys. and math. sc.; associate professor.

Khakimov Zulfat Niyazovich – e-mail: znkhakimov@stud.kpfu.ru; graduate student.

Khabibullina Guzel Zabirovna – e-mail: hg21980@rambler.ru; phone: +79274057021; the Department of Relativity and Gravity; cand. of ped. sc.; associate professor.

УДК 004.8

DOI 10.18522/2311-3103-2024-4-144-151

М.Д. Трегубенко

АНАЛИЗ МЕТОДОВ КОМПЬЮТЕРНОГО ЗРЕНИЯ ДЛЯ РАСПОЗНАВАНИЯ ДЕФЕКТОВ СОЛНЕЧНЫХ ПАНЕЛЕЙ (ОБЗОР)

В современном мире, где экологические проблемы становятся всё более актуальными, поиск альтернативных источников энергии становится приоритетной задачей. Одним из наиболее перспективных направлений является солнечная энергетика. Солнечная энергия является возобновляемым источником энергии, что делает её привлекательной для использования в различных областях, включая производство электроэнергии, отопление и охлаждение зданий, а также транспорт. Развитие солнечной энергетика может способствовать решению ряда экологических проблем, таких как загрязнение окружающей среды и изменение климата. Однако, оборудование для солнечных панелей подвержено различным типам дефектов и загрязнений. Неисправности могут негативно влиять на производительность и эффективность солнечных панелей, поэтому их обнаружение является критически важным для повышения надёжности и долговечности фотоэлектрических систем генерации энергии. Эффективный поиск дефектов позволяет минимизировать потери энергии, повысить надёжность системы и срок службы оборудования, а также снизить затраты на обслуживание. Кроме того, повышение производительности электрического оборудования способствует устойчивому развитию альтернативной энергетики, что позволяет уменьшить зависимость от традиционных источников энергии и снизить выбросы парниковых газов. Статья представляет собой обзор существующих методов обнаружения различных дефектов солнечных панелей с помощью методов компьютерного зрения и глубокого обучения. Для поиска неисправностей можно использовать изображения, полученные с помощью инфракрасной термографии (ИК), электролюминесцентной (ЭЛ) визуализации, либо в видимом спектре. Данная работа включает в себя анализ преимуществ и недостатков существующих методов поиска дефектов и загрязнений солнечных панелей, обсуждение факторов, влияющих на их эффективность, и представляет выводы по возможным дальнейшим исследованиям в данной сфере.

Компьютерное зрение; глубокое обучение; солнечные панели; нейронные сети детекция.

M.D. Tregubenko

ANALYSIS OF COMPUTER VISION METHODS FOR RECOGNISING SOLAR PANEL DEFECTS (REVIEW)

In today's world, where environmental problems are becoming more and more urgent, the search for alternative energy sources is becoming a priority. One of the most promising areas is solar energy. Solar energy is a renewable energy source, which makes it attractive for use in various areas, including power generation, heating and cooling of buildings, and transport. The development of solar energy can contribute to solving a number of environmental problems such as pollution and climate change. However, solar panel equipment is subject to various types of defects and contamination. Defects can adversely affect the performance and efficiency of solar panels, so their detection is critical to improve the reliability and durability of photovoltaic power generation systems. Effective fault finding can minimise energy losses, improve system reliability and equipment life, and reduce maintenance costs. In addition, improved performance of electrical equipment contributes to the sustainable development of alternative energy, thus reducing dependence on conventional energy sources and reducing greenhouse gas emissions. The paper presents an overview of existing methods for detecting various solar panel faults using computer vision