

## Локальные методы прогнозирования с выбором преобразования\*

*С. В. Цыганова*

*schiavoni@mail.com*

Московский физико-технический институт, ФУПМ, каф. «Интеллектуальные системы»

В работе описан алгоритм локального прогнозирования с учетом преобразований, позволяющий выявить похожие во введенной метрике интервалы временного ряда. Рассмотрено понятие инвариантных преобразований, их обнаружение и выбор наиболее подходящих для решения задачи прогнозирования. Работа алгоритма проиллюстрирована на данных потребления электроэнергии и на синтетических данных.

**Ключевые слова:** *локальное прогнозирование, функция расстояния, временной ряд, инвариантное преобразование*

## Methods of local forecasting with transformation accounting\*

*S. V. Tsyganova*

Moscow Institute of Physics and Technology

This paper considers the algorithm of local forecasting with transformation, which reveals similar intervals of time series in introduced metrics. A conception of invariant transformations is considered, and also the choice of the most suitable for forecasting problem. The work is illustrated by the data of energy consumption and synthetic data.

**Keywords:** *local forecasting, distance function, time series, invariant conversion.*

Задачи прогнозирования временных рядов имеют множество приложений в различных областях, таких как экономика, физика, медицина. Их решением является прогноз на недалекое будущее по уже известным значениям прогнозируемого ряда в предыдущие моменты времени. Данная работа посвящена методу локального прогнозирования временных рядов. Для построения прогноза используются только те части временного ряда, которые близки к конечному отрезку всего временного ряда. Близкими считаются те отрезки временных рядов, функция близости для которых мала. Для определения близких отрезков в работе исследуется линейное преобразование (сжатие, сдвиг), инварианты преобразований и функция «близости» отрезков временных рядов, которая будет являться одним из критериев адекватной работы построенного алгоритма прогнозирования. Общий локальный метод прогнозирования основан на идеях, описанных в работе Дж. Макнеймса [1] и Ю.И. Журавлева [2].

Для нахождения близких интервалов использован метод «ближайшего соседа», успешно применяемый к широкому классу прикладных задач, таких как прогнозирование объемов продаж, прогнозирование цен на электроэнергию, постановка диагноза по биоритмам человека.

Сложности при построении алгоритма – это учет пропусков в предоставленных данных. В данной работе считается, что данные представлены без пробелов.

---

Научный руководитель В. В. Стрижов

Проверка алгоритма будет производиться при помощи скользящего контроля, т.е. прогноз будет сравниваться с реальными значениями.

Вся работа разделена на четыре главы. Первая глава – это математическая постановка задачи. Во второй главе описывается алгоритм преобразования и прогнозирования с некоторыми математическими выкладками. Третья глава – вычислительный эксперимент для двух временных рядов (синтетического и потребления энергии [6]) и исследование эффективности алгоритма. В последней главе сформулирован общий вывод.

## Постановка задачи

Будем рассматривать одномерные временные ряды – ряды, в которых каждому моменту времени сопоставляется вещественное число.

$$\{t_1, t_2, \dots, t_n\} \rightarrow \{x_1, x_2, \dots, x_n\}$$

Требуется предсказать следующие  $l$  значений последовательности  $\{x_{n+1}, x_{n+2}, \dots, x_{n+l}\}$ , которые будут определяться значением предыстории  $\{x_{n-L+1}, x_{n-L+2}, \dots, x_n\}$  длины  $L$ . Для этого необходимо выполнить следующий алгоритм:

1. Выделить во всем временном ряде вектора длины

$$r : r_{min}, \dots, r_{max},$$

которые после линейных преобразований  $A$  (сжатие, сдвиг) похожи на предысторию  $S = \{x_{n-L+1}, x_{n-L+2}, \dots, x_n\}$ .

2. Найти и исследовать инварианты преобразований между двумя близкими векторами временного ряда и с их помощью найти те самые «похожие» вектора.

3. Критерий близости играет функция близости двух векторов  $\mathbf{a}$ ,  $\mathbf{b}$  – в данной работе это взвешенная метрика Евклида:

$$D_{WE}(a, b) = \sqrt{(a - b)^T \Lambda^2 (a - b)}.$$

4. Задача формулируется следующим образом:

$$\text{dist}(A(x_{k-r+1}, x_{k-r+2}, \dots, x_k), (x_{n-L+1}, x_{n-L+2}, \dots, x_n)) \rightarrow \min,$$

где  $A(x_{k-r+1}, x_{k-r+2}, \dots, x_k)$  – преобразованный близкий вектор, а  $(x_{n-L+1}, x_{n-L+2}, \dots, x_n)$  – вектор предыстории.

5. Для отыскания  $k$  близких векторов используем метод  $k$  ближайших соседей. Пусть

$$\{A_1(x_{i_1-r+1}, \dots, x_{i_1}), \dots, A_k(x_{i_k-r+1}, \dots, x_{i_k})\} -$$

это  $k$  ближайших соседей для предыстории  $\{x_{n-L+1}, x_{n-L+2}, \dots, x_n\}$ .

Прогноз вычисляется как среднее  $k$  векторов:

$$\{A_1(x_{i_1+1}, \dots, x_{i_1+l}), \dots, A_k(x_{i_k+1}, \dots, x_{i_k+l})\},$$

где среднее вычисляется как взвешенное среднее арифметическое:

$$(x_{i_1+1}, \dots, x_{i_1+l}) = \frac{\sum_{j=1}^k w_j A_j(x_{i_j+1}, \dots, x_{i_j+l})}{\sum_{j=1}^k w_j},$$

$$w_j = \left(1 - \frac{d_{ij}^2}{d_{i_{k+1}}^2}\right)^2,$$

где  $d_{i_{k+1}}^2$  – расстояние до  $k + 1$  ближайшего соседа.

## Описание алгоритма

Алгоритм включает в себя следующие этапы:

1. Нахождение преобразования  $\varphi$  по оси ОХ и выбор потенциальных соседей – векторов  $\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_m$ . Для этого во всем временном ряде  $X$  находятся точки экстремумов. Далее находятся такие векторы, чтобы точки экстремальных значений этих векторов до точек экстремальных значений предыстории имели минимальное расстояние в выбранной метрике. Максимальное отклонение, допускаемое алгоритмом – заданный параметр  $\varepsilon$ . Из этого условия для каждого  $i$ -го потенциального соседа находится коэффициент  $a_{0_i}$  растяжения по ОХ, а выбранные векторы  $\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_m$  становятся потенциальными соседями. Последующие значения –  $\mathbf{b}_1, \mathbf{b}_2, \dots, \mathbf{b}_m$  – потенциальным прогнозом в зависимости от близости соседа. Количество потенциальных соседей прямопропорционально параметру  $\varepsilon$ : чем меньше параметр, тем меньше потенциальных соседей выделяет алгоритм.

Таким образом мы находим соседние векторы  $\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_m$  для предыстории  $\{x_{n-L+1}, x_{n-L+2}, \dots, x_n\}$  у временных рядов не только с постоянным, но и с изменяющимся периодом.

2. Для каждого потенциального соседа минимизируется функция близости и находятся коэффициенты  $b_{0_i}$  растяжения по ОУ для каждого близкого вектора. Пусть  $\mathbf{y}$  – данный вектор временного ряда, а  $\mathbf{x}$  – вектор временного ряда, который необходимо преобразовать по оси ОУ, чтобы получить наиболее близкий к  $\mathbf{y}$  вектор. Тогда требуется найти минимум следующей функции:

$$F = \sum_{t=1}^l (y_t - (a + bx_t))^2.$$

Необходимые условия экстремума (более подробно смотри [3]):

$$\begin{cases} \frac{dF}{da} = -2 \sum_{t=1}^l (y_t - a - bx_t) = 0, \\ \frac{dF}{db} = -2 \sum_{t=1}^l x_t (y_t - a - bx_t) = 0. \end{cases}$$

Раскроем скобки и получим систему уравнений:

$$\begin{cases} al + b \sum_{t=1}^l x_t = \sum_{t=1}^l y_t, \\ a \sum_{t=1}^l x_t + b \sum_{t=1}^l x_t^2 = \sum_{t=1}^l x_t y_t. \end{cases}$$

Решениями системы являются:

$$\begin{cases} b = \frac{l \sum_{t=1}^l x_t y_t - (\sum_{t=1}^l x_t)(\sum_{t=1}^l y_t)}{n \sum_{t=1}^l x_t^2 - (\sum_{t=1}^l x_t)^2}, \\ a = \frac{1}{l} \sum_{t=1}^l y_t - \frac{1}{l} \sum_{t=1}^l x_t b. \end{cases}$$

3. Соседи сортируются по значению функции близости. Далее выбираются  $k$  самых близких ( $k$  – заданное число). Их потенциальный прогноз усредняется (чем меньше значение функции близости для соседа, тем больший вклад дает  $k$ -й потенциальный прогноз в усреднение).

4. Построение прогноза и вычисление ошибки с помощью скользящего контроля. Для сравнения всех прогнозов в работе используется суммарная абсолютная ошибка отклонения прогноза от действительных значений. Обозначим  $\mathbf{f} = (f_{n+1}, \dots, f_{n+l})$  – точное значение временного ряда и  $\tilde{\mathbf{f}} = (\tilde{f}_{n+1}, \dots, \tilde{f}_{n+l})$  – полученный алгоритмом прогноз. Тогда качество алгоритмов сравнивается при помощи следующей величины:

$$E = \frac{1}{l} \sum_{j=1}^l |f_{n+j} - \tilde{f}_{n+j}|.$$

Этот функционал ошибки зависит только от абсолютного отклонения прогноза от точных значений временного ряда и не зависит от их величины.

### Вычислительный эксперимент и эффективность

Данный метод прогнозирования предназначен для прогнозирования временных рядов с переменным периодом, что дает алгоритму преимущества перед алгоритмом, использующим преобразования сжатия и сдвига по оси ОУ и описанным в работе В. Федоровой [4].

Рассмотрим следующий пример – спрогнозируем модельный временной ряд :

$$y = \sin(x^2)$$

Сравним работу следующих двух алгоритмов – с использованием преобразования по ОХ и без:

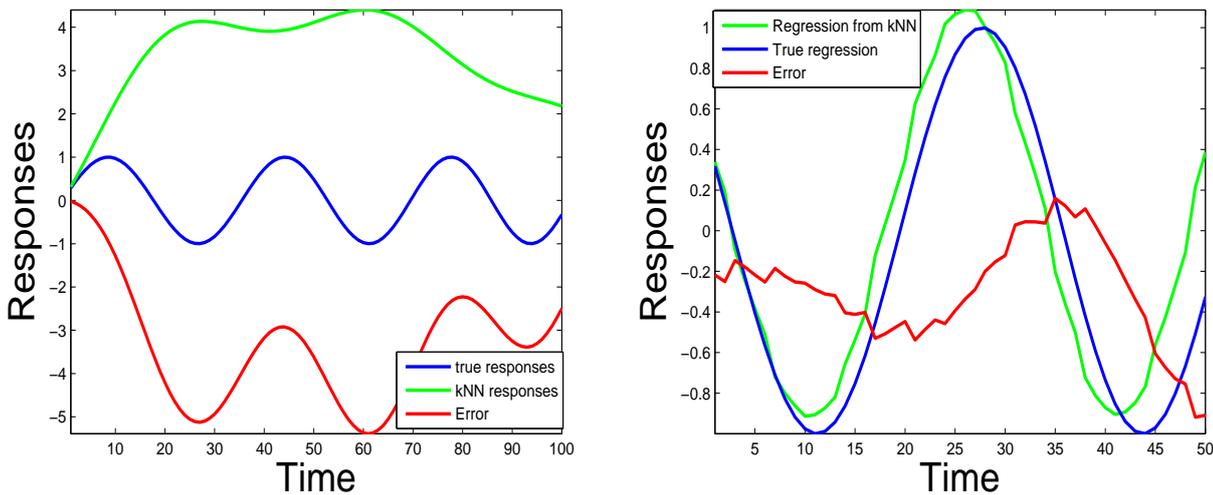


Рис. 1. Прогноз с использованием преобразования по ОХ (справа) и без (слева)

Теперь сравним работу алгоритмов на реальных данных – будем прогнозировать потребление энергии на один день вперед. График потребления электроэнергии за последние несколько дней (625 временных точек) выглядит следующим образом:

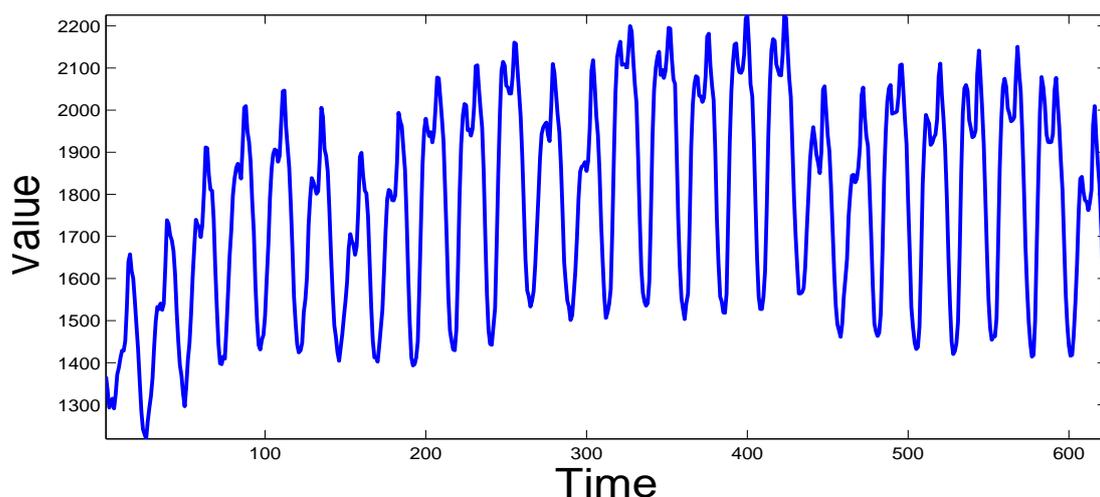


Рис. 2. график потребления электроэнергии за несколько дней

Результат работы алгоритмов:

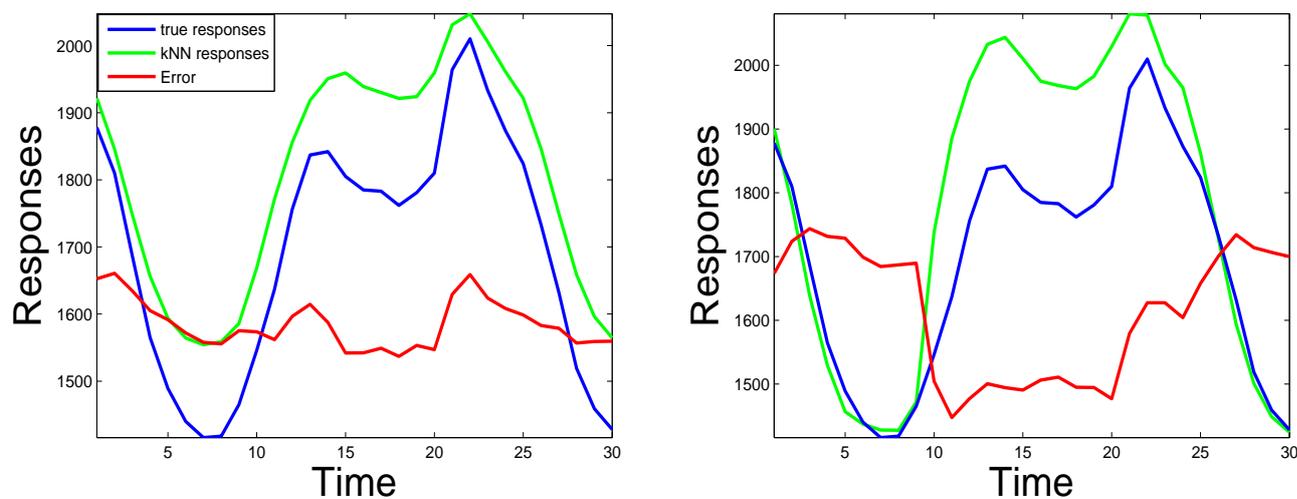


Рис. 3. Прогноз с использованием преобразования по ОХ (справа) и без (слева)

Видно, что уже на такой небольшой выборке заметно улучшение прогноза по сравнению с алгоритмом, не использующим преобразование по оси ОХ – в особенности на первых точках прогноза.

Рассмотрим теперь в 10 раз больший временной ряд (тот же самый временной ряд, но с большей историей) и получим следующие результаты:

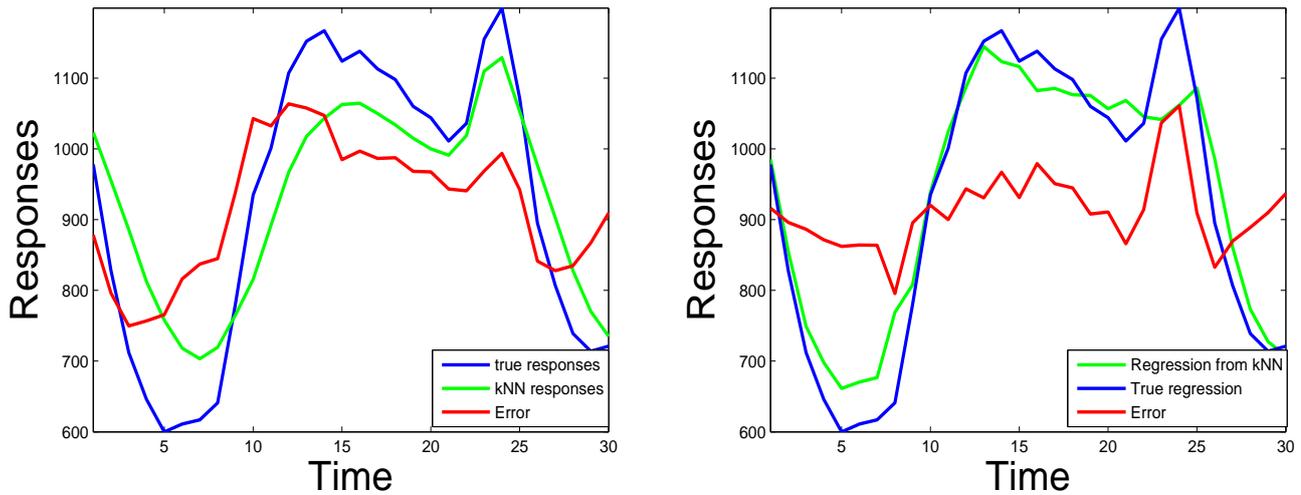


Рис. 4. Прогноз с использованием преобразования по ОХ (справа) и без (слева)

Алгоритм, использующий преобразование по оси ОХ прогнозирует намного лучше, нежели алгоритм, не использующий это преобразование. Кроме того, на такой большой выборке первый алгоритм затрачивает значительно меньшее время и ресурсов вычислительной машины, так как ищет коэффициенты преобразований не для всех возможных интервалов временного ряда, а для уже отобранных потенциальных соседей.

Точность прогноза сильно зависит от выбора значений параметров – это количество соседей  $k$ , длина предыстории  $L$  и параметр  $\varepsilon$  (максимальная ошибка при совмещении точек экстремумов потенциальных соседей и предыстории). Как уже было сказано во главе «Описание алгоритма», количество потенциальных соседей  $m$  пропорционально значению параметра  $\varepsilon$ . Алгоритм отбирает  $k$  наилучших из  $m$  потенциальных соседей после преобразований. Кажется, что если увеличивать параметр  $\varepsilon$ , то это не повлияет на результат – лучшие останутся лучшими и качество прогноза не изменится. Для опровержения этого был проведен следующий эксперимент, в котором исследовался функционал ошибки  $E$  прогноза от изменяющегося параметра  $\varepsilon$ . Результаты эксперимента представлены на следующем графике:

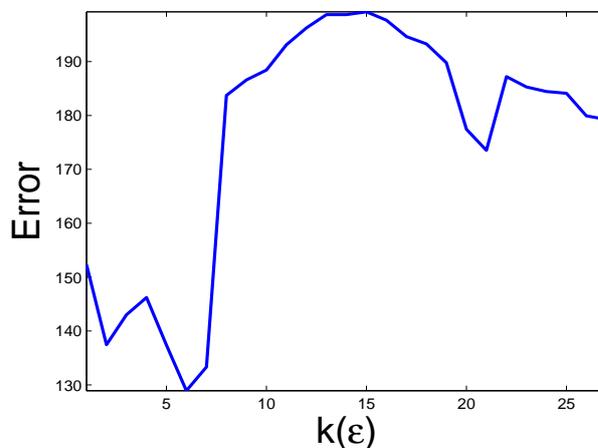


Рис. 5. Значение функционала ошибки от параметра  $\varepsilon$

При увеличении параметра  $\varepsilon$  функционал ошибки  $E$  возрастает, что ещё раз подтверждает предположение о том, что преобразование по оси  $OX$  имеет большое значение.

## Заключение

Итак, в работе был рассмотрен алгоритм локального прогнозирования, использующий аффинные преобразования (сжатие, сдвиг) временного ряда по осям  $OX$  и  $OY$  и основанный на методе  $kNN$  ( $k$  ближайших соседей). Алгоритм был протестирован на модельных и реальных данных и показал хорошие результаты. В ходе сравнения работы алгоритма с алгоритмом, использующим преобразования только по оси  $OY$ , выяснилось, что преобразование по оси  $OX$  играет достаточно большую роль в прогнозировании методом  $kNN$ , не только улучшая качество прогноза, но и уменьшая затрачиваемые вычислительные ресурсы.

## Литература

- [1] McNames J., *Innovations in local modeling for time series prediction* // Ph.D. Thesis, Stanford University, 1999.
- [2] Журавлев, Ю. И., Рязанов, В. В., и Сенько, О. В. *Распознавание. Математические методы. Программная система. Практические применения.* // Фазис, Москва, 2005.
- [3] Магнус, Я. Р., Катышев, П. К., Пересецкий, А. А. *Эконометрика* // Дело, 2004, стр. 34-37
- [4] Федорова, В. П., *Локальные методы прогнозирования временных рядов* // Москва, 2009.
- [5] Воронцов, К. В. Курс лекций *Математические методы обучения по прецедентам*
- [6] Временные ряды прогнозирования электроэнергии <http://www.neural-forecasting-competition.com>
- [7] Дуда, Р., Харт, П. *Распознавание образов и анализ сцен* // Мир, Москва, 1976