

**УДК 519.216.3**

***К. В. Воронцов, Е. В. Егорова***

Вычислительный центр РАН,

г. Москва, Россия

voron@ccas.ru

## **ДИНАМИЧЕСКИ АДАПТИРУЕМЫЕ КОМПОЗИЦИИ АЛГОРИТМОВ ПРОГНОЗИРОВАНИЯ**

### **АННОТАЦИЯ**

В статье рассматриваются три различных метода динамической перенастройки весов в линейных композициях алгоритмов прогнозирования. Экспериментально показано, что требование неотрицательности весов не только улучшает качество прогнозов, но и выступает в роли регуляризатора, повышая устойчивость композиции.

### **ВВЕДЕНИЕ**

При прогнозировании зашумленных нестационарных временных рядов возникает проблема выбора адекватной модели временного ряда. Модели нестационарных процессов, такие как GARCH [1] расширяют область применимости классических статистических моделей. Однако они опираются на априорные предположения о природе нестационарности (например, гипотезу о непостоянстве дисперсии) и потому являются в той же степени эвристическими, что и классические стационарные модели типа ARIMA [1]. Более универсальной представляется идея совместного применения нескольких эвристических алгоритмов прогнозирования [2]. В этом случае принимается следующая гипотеза: ряд может переходить из одного состояния в другое, причем в каждом состоянии его поведение неплохо описывается одной из стандартных моделей. На Рис. 1 показана динамика средних ошибок прогнозирования одного и того же временного ряда шестью моделями ARIMA. Видны три интервала, когда точность прогнозов одной из моделей соответственно хуже, сравнима, и лучше остальных. Длительность этих интервалов представляется вполне достаточной, чтобы успеть включить наиболее удачные модели и отключить менее удачные.




Рис. 1. Экспоненциально сглаженные средние ошибки прогнозирования для 6 базовых алгоритмов типа ARIMA (по реальному временному ряду объемов продаж).

## ДИНАМИЧЕСКИ АДАПТИРУЕМЫЕ ЛИНЕЙНЫЕ КОМПОЗИЦИИ

Пусть для прогнозирования временного ряда  $y(t)$ ,  $t = 1, \dots, T$ , используются  $p$  базовых алгоритмов  $b_1, \dots, b_p$ . Прогноз  $b_i(t)$  в момент времени  $t$  вычисляется алгоритмом  $b_i$  с использованием информации, доступной на интервале  $[1, \dots, t-1]$ . Постоим алгоритм  $a(t)$  как линейную комбинацию базовых алгоритмов:

$$a(t) = \sum_{i=1}^p w_{it} b_i(t), \quad \sum_{i=1}^p w_{it} = 1, \quad t = 1, \dots, T. \quad (1)$$

Веса алгоритмов  $w_{it}$ , используемые для прогнозирования в момент  $t$ , вычисляются по данным предыстории  $[1, \dots, t-1]$ . Будем называть алгоритмическую композицию (1) динамически адаптируемой, если веса обновляются в каждый момент времени непосредственно перед вычислением прогноза.

Рассмотрим следующие методы динамической адаптации весов.

1. MS( $\theta$ ) — выбор наилучшей модели (model selection) по последнему наиболее актуальному отрезку ряда. Критерием выбора служит функционал экспоненциально сглаженной средней ошибки прогнозов:

$$w_{it} = \begin{cases} 1, & i = I(t) \\ 0, & i \neq I(t) \end{cases}, \quad \text{где } I(t) = \arg \min_{i=1, \dots, p} \sum_{\tau=1}^{t-1} \theta^{t-\tau-1} (b_i(\tau) - y(\tau))^2,$$

т. е.  $I(t)$  — номер модели, выбираемой в качестве наилучшей в момент времени  $t$ . Параметр  $\theta \in [0, 1]$  задаёт «скорость забывания» предыстории. При  $\theta = 1$  все точки ряда учитываются с одинаковым весом, при  $\theta = 0$  учитывается только последняя точка, при  $0 < \theta < 1$  веса более старых точек убывают по геометрической прогрессии.

2.  $LS(\theta, \lambda)$  — метод наименьших квадратов с регуляризацией:

$$w_t = \arg \min_w \sum_{\tau=1}^{t-1} \theta^{t-\tau-1} \left( \sum_{i=1}^p w_i b_i(\tau) - y(\tau) \right)^2 + \lambda \sum_{i=1}^p (w_i - w_{i,t-1})^2,$$

где минимум берётся по вектору весов  $w = (w_1, \dots, w_p)$ , удовлетворяющему условию нормировки из (1). Параметр  $\theta \in [0, 1]$  задаёт «скорость забывания» предыстории, аналогично методу MS. Второе слагаемое представляет собой штраф за отклонение вектора весов  $w_t$  от вектора весов  $w_{t-1}$  в предыдущий момент времени. Параметр регуляризации  $\lambda \geq 0$  позволяет найти компромисс между точностью прогнозов на обучающих данных и устойчивостью весов во времени.

3.  $NNLS(\theta, \lambda)$  — метод наименьших квадратов с регуляризацией и неотрицательными весами алгоритмов (non-negative least squares). Отличается от предыдущего метода введением дополнительного условия  $w_{it} \geq 0$ . В этом случае композицию (1) можно рассматривать как линейную монотонную корректирующую операцию над эвристическими алгоритмами прогнозирования [2]. Требование монотонности является вполне естественным для корректирующих операций и означает, что если базовый алгоритм имеет низкое качество, то лучше вовсе отключить его, чем пытаться инвертировать его прогнозы.

В качестве эталонов для сравнения будем рассматривать ещё два метода, не обладающих свойством динамической адаптации весов.

4. AVR — среднее базовых прогнозов:  $w_{it} = 1/p$  для всех  $i = 1, \dots, p$ ,  $t = 1, \dots, T$ .

5. LS-ALL — линейная комбинация, построенная по всему ряду:

$$w_t = \arg \min_w \sum_{\tau=1}^T \left( \sum_{i=1}^p w_i b_i(\tau) - y(\tau) \right)^2.$$

## РЕЗУЛЬТАТЫ ЭКСПЕРИМЕНТОВ

Точность перечисленных методов сравнивалась на реальных данных ежедневных объёмов продаж товаров в супермаркете. В качестве базовых алгоритмов использовались 6 стандартных моделей типа ARIMA. Точность прогнозирования оценивалась по функционалу скользящего контроля  $Q = \sum_{t=T_0}^T (a(t) - y(t))^2$  на интервале времени  $[T_0, T]$  длиной 620 точек.

В следующей таблице приведена средняя ошибка прогнозов базовых алгоритмов и методов динамической адаптации при оптимальных значениях параметров  $\theta$  и  $\lambda$ .

Базовые алгоритмы	Методы динамической адаптации весов	
0.714	<b>NNLS(0, <math>\lambda</math>)</b>	<b>0.590</b>
0.729	MS( $\theta$ )	0.596
0.753	LS(0, $\lambda$ )	0.659
0.762	LS-ALL	0.714
0.766	AVR	0.729
0.779	MS(1)	0.911

Наилучшие результаты дают методы NNLS(0,  $\lambda$ ) и MS( $\theta$ ) при оптимальном значении  $\theta \approx 0.7$ , что приблизительно соответствует выбору наилучшей модели по 3–5 последним точкам. Это как раз тот интервал времени, на котором представляется возможной идентификация момента переключения с одной модели на другую, см. Рис. 1.

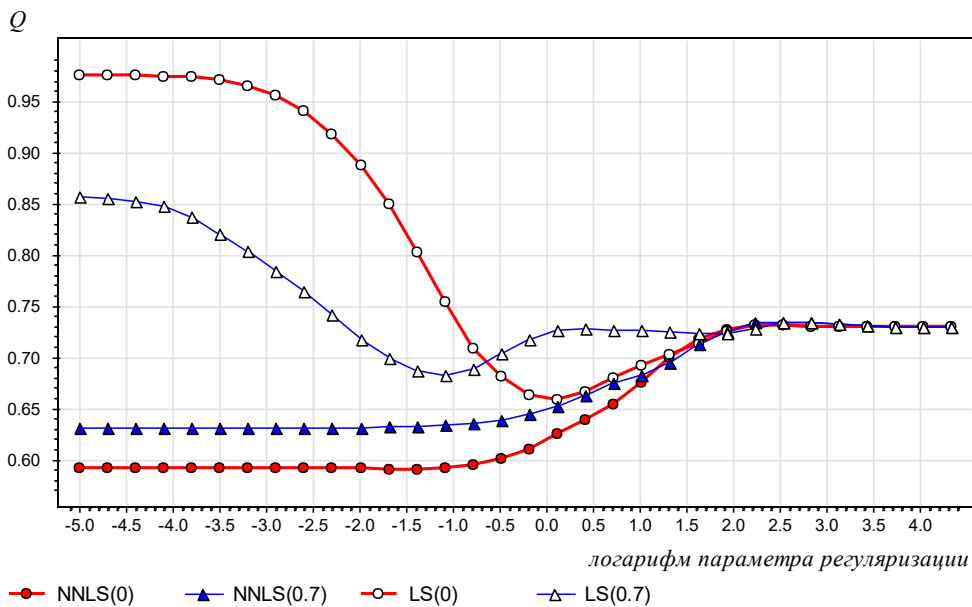


Рис. 2. Зависимость точности прогнозов от параметра регуляризации.

Интересные результаты показал анализ зависимости точности прогнозов  $Q$  от параметра регуляризации  $\lambda$ , Рис. 2. Без ограничения неотрицательности весов график  $Q(\lambda)$  имеет классическую форму с чётко выраженным минимумом, соответствующим оптимальному значению параметра регуляризации. При ограничении неотрицательности весов функция  $Q(\lambda)$  становится практически монотонно возрастающей. Чем мень-

ше  $\lambda$ , тем лучше точность прогнозов. Она не ухудшается даже в пределе при  $\lambda \rightarrow +0$ , т. е. когда регуляризация фактически отключается. Таким образом, требование монотонности само по себе является хорошим регуляризатором. Оно не только обеспечивает отбор значимых предикторов, но и повышает устойчивость весов. Наилучшее качество прогнозирования достигается именно монотонным корректором.

## ЗАКЛЮЧЕНИЕ

Использование динамически адаптируемой линейной композиции способно увеличить точность базовых прогнозов на 20–30% в данной прикладной задаче. Точность прогнозирования оказывается наилучшей при наложении ограничения неотрицательности на веса алгоритмов в композиции. Показано, что данное ограничение играет роль регуляризатора, повышая устойчивость весов. Рассмотренные методы построения композиций применяются в системе Forecsys Goods4Cast, предназначенной для прогнозирования объемов продаж в ритейлинговых сетях.

Работа выполнена при поддержке Российского Фонда Фундаментальных Исследований, проекты 04-01-08063-офи, 05-01-00877.

## ЛИТЕРАТУРА

1. Магнус Я. Р., Катышев П. К., Пересецкий А. А. Эконометрика. Начальный курс. М.: Дело. 2004.
2. Воронцов К. В. Оптимизационные методы линейной и монотонной коррекции в алгебраическом подходе к проблеме распознавания // ЖВМ и МФ. — 2000. — Т. 40, № 1. — С. 166–176.

***К. В. Воронцов, Е. В. Егорова***

### **Динамічно адаптуємі композиції алгоритмів прогнозування**

У статті розглядаються три різних методи динамічного перенастроювання ваг у лінійних композиціях алгоритмів прогнозування. Експериментально показано, що вимога незаперечності ваг не тільки поліпшує якість прогнозів, але і вне-ступає в ролі регуляризатора, підвищуючи стійкість композиції.

***K. V. Vorontsov, E. V. Egorova***

### **Dynamically updating compositions of forecasting algorithms**

The linear ensembles of forecasting algorithms are considered with three different methods of dynamic weights updating. It is experimentally shown that a requirement to weights be nonnegative favors better generalization and plays a regularization role increasing the weights stability.