

Прогнозирование в разрезе SKU

Новые возможности повышения
адекватности прогнозов

Алексей Субботин
Loginom Company (ex. BaseGroup Labs)



Трудности прогноза спроса

- Большое количество товарных позиций
- Особенности каждой SKU: сезонность, характерный масштаб объемов
- Наличие товаров-заменителей
- Изменение ассортимента: исключение старых и появление новых SKU
- SKU с редкими продажами

Путь 1: попозиционный прогноз

Достоинства:

1. Возможность учета индивидуальных особенностей (сезонность, редкие продажи, ...)

Недостатки:

1. Трудоемкость поддержки и актуализации одновременно множества моделей
2. Длительность обсчетов
3. Потеря информации об отношениях между позициями (заменители, сопутствующие)
4. Игнорирование изменений в номенклатуре
5. Сложности построения композитных моделей из-за переменного числа SKU

Попозиционный прогноз

Пример расчета времени:

- Количество SKU – 100 000
- Количество моделей на 1 SKU – 10
- Время расчета 1 модели - 100 мсек

Итого:

- $100\,000 \text{ SKU} * 10 \text{ моделей} * 100 \text{ мсек} = 27.8 \text{ часов}$

Ошиблись? Нужны правки? Переделываем...

Путь 2: прогноз по группам


Достоинства:

1. Более стабильные прогнозы
2. Небольшое количество групп
3. Редкие изменения групп
4. Возможность обработки «сверху вниз»

Недостатки:

1. Нет информации по конкретному SKU, а это – конечная цель
2. Сложность получения из прогноза группы прогноза по SKU
3. Сложность балансировки попозиционного прогноза

Путь 2 - прогноз по группам




Адекватность – необходимое (но **не достаточное!**) условие точности.


Неадекватный прогноз спроса:

- Некачественное планирование
- Избытки/недостатки на складах
- Ухудшение отношений с поставщиками
- Потеря денег


Адекватность это...




Интуитивная понятность



Адекватность это...



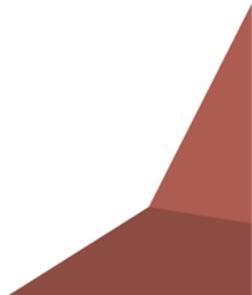
Учёт индивидуальных особенностей SKU



Адекватность это...

Универсальный алгоритм,
одинаково работающий с
любыми данными, не
приспосабливаясь специально
к «модельным» ситуациям


Решение

1. Объединить преимущества двух подходов
 2. Стараться максимально учесть априорные данные
- 

Алгоритм



Выбор базовой модели



$$\sum_{k=1}^N \hat{y}_{k,N-1+i} = \hat{Y}_{N-1+i},$$
$$i = 1..P$$



Проблемы функциональных трендов (линейный, полиномиальный...):

- Малое количество и глобальность степеней свободы
- Проблемы с точностью для моделей высокого порядка

Слайны



Индивидуальный тренд



Сглаживание



- $\hat{s}(t) = \arg \min_{\xi(t)} \{p \cdot \|\xi - s\|_2^2 + (1 - p) \cdot \|\xi''(t)\|_2^2\}$

Метод конечных элементов

- $\hat{s}(t) = \sum_{j=1}^K \beta_j B_j(t)$



- $\hat{s}(t_i) = \sum_{j: B_j(t_i) \neq 0} \beta_j B_j(t_i)$

Индивидуальный тренд





$$\frac{d}{d\boldsymbol{\beta}} \left\{ p \cdot \sum_{i=1}^N [\hat{s}(t_i) - s(t_i)]^2 + (1-p) \cdot \left(\int_{t_1}^{t_N} \hat{s}''(t) dt \right)^2 \right\} =$$
$$= \frac{d}{d\boldsymbol{\beta}} \left\{ p \cdot \sum_{i=1}^N \left[\sum_{j: B_j \neq 0} \beta_j B_j(t_i) - s(t_i) \right]^2 + (1-p) \cdot \left(\sum_j \beta_j \cdot \int_{B_j(t) \neq 0} B_j''(t) dt \right)^2 \right\} = 0$$

Индивидуальный тренд



$$\{p \cdot \mathbf{B}^T \mathbf{B} + (1 - p) \cdot \mathbf{Q}\} \cdot \boldsymbol{\beta} = p \cdot \mathbf{B}^T \cdot \mathbf{s}$$
$$\Rightarrow \boldsymbol{\beta}$$

Базовая модель тренда



Преимущества регрессионных сплайнов:


- Степеней свободы много, их число легко контролируется, и они локализованы
- Параметры можно подбирать грубо
- Нет проблем с устойчивостью вычислений
- Уравнения сводятся к системам с разреженными матрицами – время $O(N)$ вместо $O(N^3)$

Учет сезонности

$$\begin{aligned} & \{p \cdot \mathbf{B}^T \mathbf{B} + (1 - p) \cdot \mathbf{Q}\} \cdot \boldsymbol{\beta} \\ & = p \cdot \mathbf{B}^T \cdot \mathbf{s} \end{aligned}$$

$$\begin{aligned} & \{p \cdot \mathbf{B}^T \mathbf{B} + (1 - p) \cdot \mathbf{Q}\} \cdot \boldsymbol{\beta} \\ & = p \cdot \mathbf{B}^T \cdot \text{diag}(\boldsymbol{\eta})^{-1} \cdot \mathbf{s} \end{aligned}$$

Подбор степени сглаживания



$$\frac{1}{1 + \left(\frac{\omega}{\omega_c}\right)^4},$$

$$\omega_c = \left(\frac{p}{1-p}\right)^{\frac{1}{4}}$$

Редкие SKU без сезонности

Исключаем то, что невозможно прогнозировать. Необходимо использовать другие подходы, например, перенести моделирование на более крупный временной масштаб.

Объединение трендов в общую модель

$$\begin{aligned}\Phi(\hat{s}_1, \dots, \hat{s}_M) &= \sum_{k=1}^M \alpha_k \cdot \Phi_k(\hat{s}_k) = \\ &= \sum_{k=1}^M \alpha_k \cdot \{p_k \cdot \|\hat{\mathbf{s}}_k - \mathbf{diag}(\boldsymbol{\eta}_k)^{-1} \mathbf{s}_k\|_2^2 + (1 - p_k) \cdot \|\hat{s}_k''(t)\|_2^2\} \\ &\rightarrow \min\end{aligned}$$

$$\sum_{k=1}^N [\eta_{k,N-1+i} \hat{s}_{k,N-1+i}]_+ = \hat{Y}_{N-1+i}, \quad i = 1..P$$

$$[x]_+ = \begin{cases} x, & x \geq 0 \\ 0, & \text{otherwise} \end{cases}$$

Балансировка функционала – «изюминка» модели

$$\alpha_k \sim \left[\text{Var} \left(p_k \cdot \mathbf{B}_k^T \cdot \text{diag}(\boldsymbol{\eta}_k)^{-1} \cdot \mathbf{s}_k \right) \right]^{-\frac{1}{2}}$$

Решение

- Выпуклая оптимизация с нелинейными ограничениями
- Метод множителей Лагранжа

$$\begin{aligned} & \frac{\partial}{\partial(\boldsymbol{\beta}, \boldsymbol{\lambda})} \Lambda(\hat{s}_1, \dots, \hat{s}_M) = \\ & = \frac{\partial}{\partial(\boldsymbol{\beta}, \boldsymbol{\lambda})} \left\{ \Phi(\hat{s}_1, \dots, \hat{s}_M) + \sum_{k=1}^N \lambda_k \cdot g_k(\hat{s}_1, \dots, \hat{s}_M) \right\} = 0 \end{aligned}$$


Метод активных множеств

$$\Phi(\hat{s}_1, \dots, \hat{s}_M) = \sum_{k=1}^M \alpha_k \cdot \Phi_k(\hat{s}_k) = \rightarrow \min$$

$$\sum_{k=1}^N [\eta_{k,N-1+i} \hat{s}_{k,N-1+i}]_+ = \hat{Y}_{N-1+i}, \quad i = 1..P$$

$$\mathbf{F} = \begin{pmatrix} \mathbf{H} & \mathbf{A}^T \\ \mathbf{A} & \mathbf{0} \end{pmatrix}$$

Алгоритм: оптимизация



Эквивалентное ядро

$$\kappa(u) = \frac{1}{2} \cdot e^{-\frac{|u|}{\sqrt{2}}} \cdot \sin\left(\frac{|u|}{\sqrt{2}} + \frac{\pi}{4}\right)$$

$$d = l \cdot \frac{2\pi}{\omega_c} = l \cdot 2\pi \cdot \left(\frac{1-p}{p}\right)^{\frac{1}{4}}$$

1. Снижаем количество данных, требуемых для прогноза
2. Увеличиваем скорость работы.

Округление значений

- Округленная сумма не равна сумме округленных слагаемых
- Разные способы распределения дефекта: пропорционально, поровну, «всё одному»

Выводы

1. Быстрый метод с низкими требованиями по трудоемкости
2. Автоматическая балансировка и учет масштабов рядов
3. Адекватность на модельных данных, доверие к результату



Вопросы?

Алексей Субботин

aleksey.subbotin@loginom.ru

Loginom Company

(ex. BaseGroup Labs)

loginom.ru