

## Формулировка GARCH-процесса

Обозначим через  $\sigma_t^2$  условную дисперсию  $\varepsilon_t$  по прошлой информации  $\Omega_t$ :

$$\text{Var}(\varepsilon_t | \Omega_t) = \sigma_t^2.$$

В данном случае  $\Omega_t$  — прошлая история процесса  $\varepsilon_t$ :

$$\Omega_t = \{\varepsilon_{t-j}\}_{j=1}^{\infty}.$$

Если процесс  $\varepsilon_t$  является GARCH( $k, l$ ), то он задается следующим рекуррентным соотношением для условной дисперсии  $\varepsilon_t$ :

$$\sigma_t^2 = \mu + \sum_{j=1}^k \gamma_j \varepsilon_{t-j}^2 + \sum_{j=1}^l \delta_j \sigma_{t-j}^2. \quad (1)$$

Предполагается, что

$$E(\varepsilon_t | \Omega_t) = 0,$$

а также что нормированные величины  $\varepsilon_t$  независимы и одинаково распределены:

$$\xi_t = \frac{\varepsilon_t}{\sigma_t} \sim \text{IID}.$$

## Регрессия с GARCH-процессом в ошибке

Регрессия с GARCH-процессом в ошибке имеет вид

$$y_t = X_t \beta + \varepsilon_t, \quad t = 1, \dots, T.$$

Здесь  $y_t$  — зависимая переменная,  $X_t$  — вектор-строка ( $1 \times m$ ) независимых переменных,  $\beta$  — вектор-столбец ( $m \times 1$ ) коэффициентов регрессии,  $\varepsilon_t$  — ошибка, представляющая собой GARCH-процесс.

В матричной записи

$$y = X \beta + \varepsilon.$$

## Функция правдоподобия

Предположение об условной нормальности  $\varepsilon_t$ :

$$\varepsilon_t | \sigma_t^2 \sim N(0, \sigma_t^2).$$

В предположении условной нормальности вклад в логарифмическую функцию правдоподобия  $t$ -го наблюдения равен

$$\ell_t = -\frac{1}{2} \ln 2\pi - \frac{1}{2} \ln \sigma_t^2 - \frac{1}{2} \frac{\varepsilon_t^2}{\sigma_t^2}, \quad t = 1, \dots, T.$$

Здесь  $\varepsilon_t$  и  $\sigma_t^2$  следует рассматривать как функции от неизвестных параметров  $\theta$ :

$$\varepsilon_t = \varepsilon_t(\theta) \quad \text{и} \quad \sigma_t^2 = \sigma_t^2(\theta).$$

В вектор  $\theta$  должны войти параметры  $\beta, \mu, \gamma, \delta$  и любые другие неизвестные параметры (см. ниже).

Логарифмическая функция правдоподобия равна

$$\ell(\theta) = -\frac{1}{2} \left( T \ln 2\pi + \sum_{t=1}^T \left[ \ln \sigma_t^2(\theta) + \frac{\varepsilon_t^2(\theta)}{\sigma_t^2(\theta)} \right] \right).$$

Оценки максимального правдоподобия по определению должны максимизировать логарифмическую функцию правдоподобия  $\ell$  по неизвестным параметрам  $\theta$ .

Оценки максимального правдоподобия являются корнями уравнения правдоподобия:

$$\frac{\partial \ell(\theta)}{\partial \theta^T} = \mathbf{0}.$$

### Начальные значения условной дисперсии

Для того, чтобы использовать рекуррентную формулу (1) для расчета условной дисперсии, используемой в функции правдоподобия, нужны начальные значения  $\sigma_t^2$ ,  $t = \min\{1, k+1-l\}, \dots, k$ . Один из способов — рассматривать эти начальные значения как параметры, которые требуется оценить. Обозначим эти параметры через  $\eta_t$  ( $= \sigma_t^2$ ), тогда рекуррентная формула примет вид:

$$\sigma_t^2(\theta) = \begin{cases} \eta_t, & t = \min\{1, k+1-l\}, \dots, k \\ \mu + \sum_{j=1}^k \gamma_j \varepsilon_{t-j}^2(\theta) + \sum_{j=1}^l \delta_j \sigma_{t-j}^2(\theta), & t = k+1, \dots, T. \end{cases} \quad (2)$$

Можно также использовать вместо начальных значений безусловную дисперсию:

$$\sigma_t^2 = \sigma^2, \quad t = \min\{1, k+1-l\}, \dots, k,$$

где

$$\sigma^2 = \frac{\mu}{1 - \sum_{j=1}^k \gamma_j - \sum_{j=1}^l \delta_j}.$$

При этом предполагается, что

$$1 - \sum_{j=1}^k \gamma_j - \sum_{j=1}^l \delta_j > 0,$$

то есть, что GARCH-процесс стационарен.

В дальнейшем рассмотрим только первый способ (с параметрами  $\eta_t$ ). При этом в вектор  $\theta$  следует включить и  $\eta_t$ .

Если, GARCH-процесс стационарен, то с асимптотической точки зрения выбор начальных приближений не играет роли.

### Метод оценивания

Для оценивания модели можно применить следующий общий итерационный метод:

$$\theta^{r+1} = \theta^r + \left( \hat{\mathfrak{Z}}(\theta^r) \right)^{-1} \mathbf{g}(\theta^r), \quad (3)$$

где

$$\mathbf{g}(\theta) = \frac{\partial \ell(\theta)}{\partial \theta^T} —$$

градиент логарифмической функции правдоподобия (вектор-столбец),  $\hat{\mathfrak{Z}}(\theta)$  — оценка информационной матрицы,  $r$  — номер итерации.

Стационарная точка итераций ( $\theta^{r+1} = \theta^r$ ) соответствует решению уравнения правдоподобия:

$$\mathbf{g}(\boldsymbol{\theta}^r) = \mathbf{0}.$$

Алгоритм (3) на практике применяют обычно в несколько модифицированном виде:

$$\boldsymbol{\theta}^{r+1} = \boldsymbol{\theta}^r + \lambda \left( \hat{\mathfrak{S}}(\boldsymbol{\theta}^r) \right)^{-1} \mathbf{g}(\boldsymbol{\theta}^r),$$

где  $\lambda > 0$ . Такая модификация нужна для повышения устойчивости алгоритма. Например, при выборе  $\lambda = 1$  функция правдоподобия может уменьшиться или шаг может попасть в недопустимую область (в GARCH-модели это случай, когда одна из оценок условной дисперсии становится отрицательной). В таких случаях множитель  $\lambda$  уменьшают до тех пор, пока не достигнут требуемого — увеличения функции правдоподобия или попадания в допустимую область.

Информационную матрицу можно оценить разными методами. Это, например, может быть матрица Гессе логарифмической функции правдоподобия со знаком минус:

$$\hat{\mathfrak{S}}(\boldsymbol{\theta}) = - \frac{\partial^2 \ell(\boldsymbol{\theta})}{\partial \boldsymbol{\theta} \partial \boldsymbol{\theta}^T}.$$

при этом итерации (3) соответствуют классическому методу Ньютона. К сожалению, в модели GARCH матрицу Гессе довольно трудно вычислять.

Другой метод (его применяли те, кто предложил модель GARCH — Энгл, Боллерслев) называется методом ВННН (или методом внешнего произведения градиентов, OPG). В этом методе информационная матрица оценивается следующим способом:

$$\hat{\mathfrak{S}}(\boldsymbol{\theta}) = \mathbf{G}(\boldsymbol{\theta})^T \mathbf{G}(\boldsymbol{\theta}),$$

где  $\mathbf{G}$  — матрица вкладов в градиент отдельных наблюдений:

$$\mathbf{G}(\boldsymbol{\theta}) = \{G_t(\boldsymbol{\theta})\}_{t=1, \dots, T},$$

$$G_t(\boldsymbol{\theta}) = \frac{\partial \ell_t(\boldsymbol{\theta})}{\partial \boldsymbol{\theta}}.$$

Однако, по-видимому, наилучшим методом для оценивания GARCH является следующий. В нем оценка информационной матрицы получается по формуле:

$$\hat{\mathfrak{S}}(\boldsymbol{\theta}) = \sum_{t=1}^T \hat{\mathfrak{S}}_t(\boldsymbol{\theta}),$$

где  $\hat{\mathfrak{S}}_t(\boldsymbol{\theta})$  — информационная матрица для  $t$ -го наблюдения *условная* по прошлой информации  $\Omega_t$ :

$$\hat{\mathfrak{S}}_t(\boldsymbol{\theta}) = \mathbf{E} \left( \frac{\partial \ell_t(\boldsymbol{\theta})}{\partial \boldsymbol{\theta}^T} \frac{\partial \ell_t(\boldsymbol{\theta})}{\partial \boldsymbol{\theta}} \mid \Omega_t \right) = \mathbf{E} (G_t(\boldsymbol{\theta})^T G_t(\boldsymbol{\theta}) \mid \Omega_t).$$

Для применения метода нужны формулы для расчета условной информационной матрицы  $t$ -го наблюдения,  $\hat{\mathfrak{S}}_t(\boldsymbol{\theta})$ , и для расчета градиента  $\mathbf{g}(\boldsymbol{\theta})$ . Градиент удобно разложить на вклады отдельных наблюдений:

$$\mathbf{g}(\boldsymbol{\theta})^T = \mathbf{1}^T \mathbf{G} = \sum_{t=1}^T G_t(\boldsymbol{\theta}).$$

Таким образом, требуется вычислить вклады в градиент,  $G_t(\boldsymbol{\theta})$ .

## Вычисление условной информационной матрицы $t$ -го наблюдения и вклада в градиент $t$ -го наблюдения

Продифференцируем  $\ell_t(\boldsymbol{\theta})$ , чтобы получить формулу для вклада в градиент  $t$ -го наблюдения:

$$G_t = \frac{\partial \ell_t}{\partial \boldsymbol{\theta}} = -\frac{1}{2} \frac{1}{\sigma_t^2} \frac{d\sigma_t^2}{d\boldsymbol{\theta}} + \frac{1}{2} \frac{\varepsilon_t^2}{\sigma_t^2} \frac{1}{\sigma_t^2} \frac{d\sigma_t^2}{d\boldsymbol{\theta}} - \frac{\varepsilon_t}{\sigma_t} \frac{1}{\sigma_t} \frac{d\varepsilon_t}{d\boldsymbol{\theta}}.$$

Здесь и в дальнейшем мы будем опускать аргумент  $\boldsymbol{\theta}$ .

Введем обозначения

$$\xi_t = \frac{\varepsilon_t}{\sigma_t}, \quad v_t = \xi_t^2 - 1, \quad Q_t = \frac{1}{\sigma_t} \frac{d\varepsilon_t}{d\boldsymbol{\theta}}, \quad S_t = \frac{1}{\sigma_t^2} \frac{d\sigma_t^2}{d\boldsymbol{\theta}}.$$

В этих обозначениях вклад в градиент  $t$ -го наблюдения равен

$$G_t = \xi_t Q_t + \frac{1}{2} v_t S_t.$$

Поскольку условно по прошлой информации  $\Omega_t$  вектора  $Q_t$  и  $S_t$  являются детерминированными, то

$$\hat{S}_t = \mathbf{E}(G_t^\top G_t | \Omega_t) = \mathbf{E} \left[ \left( \xi_t Q_t + \frac{1}{2} v_t S_t \right)^\top \left( \xi_t Q_t + \frac{1}{2} v_t S_t \right) | \Omega_t \right].$$

Несложно показать, что

$$\mathbf{E}(\xi_t^2) = 1, \quad \mathbf{E}(\xi_t v_t) = 0, \quad \mathbf{E}(v_t^2) = 2.$$

Отсюда

$$\hat{S}_t = Q_t^\top Q_t + \frac{1}{2} S_t^\top S_t.$$

Ниже мы подробно разберем как вычислять градиенты

$$\frac{d\sigma_t^2}{d\boldsymbol{\theta}} \quad \text{и} \quad \frac{d\varepsilon_t}{d\boldsymbol{\theta}},$$

которые нужны для вычисления  $Q_t$  и  $S_t$ .

## Искусственная регрессия

Эти преобразования показывают, что  $r$ -й шаг итерационного алгоритма (4) имеет в данном случае вид

$$\Delta^r = \boldsymbol{\theta}^{r+1} - \boldsymbol{\theta}^r = \left( \mathbf{Q}^{r\top} \mathbf{Q}^r + \frac{1}{2} \mathbf{S}^{r\top} \mathbf{S}^r \right)^{-1} \left( \mathbf{Q}^{r\top} \boldsymbol{\xi}^r + \frac{1}{2} \mathbf{S}^{r\top} \mathbf{v}^r \right),$$

где  $\mathbf{Q}$ ,  $\mathbf{S}$ ,  $\boldsymbol{\xi}$ ,  $\mathbf{v}$  — матрицы и вектора, составленные из  $Q_t$ ,  $S_t$ ,  $\xi_t$  и  $v_t$  соответственно. Шаг этого алгоритма, как несложно увидеть, можно вычислить с помощью следующей регрессии:

$$\begin{pmatrix} \boldsymbol{\xi} \\ \frac{1}{\sqrt{2}} \mathbf{v} \end{pmatrix} = \begin{bmatrix} \mathbf{Q} \\ \frac{1}{\sqrt{2}} \mathbf{S} \end{bmatrix} \Delta + \text{остатки}.$$

Заметим также, что оценка ковариационной матрицы в этой регрессии, полученная на последней итерации (когда метод сошелся), является состоятельной оценкой ковариационной матрицы оценок максимального правдоподобия в GARCH-модели:

$$\widehat{\text{Var}}(\hat{\boldsymbol{\theta}}) = \frac{\boldsymbol{\xi}^T \boldsymbol{\xi} + \frac{\mathbf{v}^T \mathbf{v}}{2}}{T} \left( \mathbf{Q}^T \mathbf{Q} + \frac{\mathbf{S}^T \mathbf{S}}{2} \right)^{-1}.$$

Таким образом, эта регрессия представляет собой то, что называется *искусственной регрессией*.

В качестве критерия остановки можно взять нецентральный коэффициент детерминации из искусственной регрессии:

$$R_{nc}^2 = 1 - \frac{\text{сумма квадратов остатков}}{\text{сумма квадратов зависимой переменной}}.$$

Можно считать, что метод сошелся, если регрессия практически не объясняет зависимую переменную, т.е. если величина  $R_{nc}^2$  мала ( $R_{nc}^2 < \phi$ ). На практике неплохо работает правило остановки с  $\phi = 10^{-11}$ .

### Вычисление градиентов остатков

Для полного описания алгоритма требуется указать способ вычисления градиентов  $d\sigma_t^2/d\boldsymbol{\theta}$  и  $d\varepsilon_t/d\boldsymbol{\theta}$ .

Поскольку по определению

$$\varepsilon_t(\boldsymbol{\theta}) = y_t - X_t \boldsymbol{\beta},$$

то

$$\frac{d\varepsilon_t}{d\boldsymbol{\theta}} = (X_t, \mathbf{0}^T).$$

Если регрессоры отсутствуют, то есть, если  $y_t$  — это непосредственно GARCH-процесс  $\varepsilon_t$  с нулевым математическим ожиданием, то градиент равен нулю и, соответственно  $Q_t = \mathbf{0}^T$ . При этом искусственная регрессия упрощается до регрессии  $1/\sqrt{2} \mathbf{v}$  на  $1/\sqrt{2} \mathbf{S}$  (множитель  $1/\sqrt{2}$  не влияет на оценки регрессии, но должен входить в ковариационную матрицу, поэтому его лучше не отбрасывать).

### Вычисление градиентов условных дисперсий

Обозначим

$$\frac{d\sigma_t^2}{d\boldsymbol{\theta}} = H_t.$$

Формулу для этих величин получим, дифференцируя по  $\boldsymbol{\theta}$  соотношение (2).

При  $t = \min\{1, k+1-1\}, \dots, k$  вектор-строка  $H_t$  будет состоять из нулей, только на месте параметра  $\eta_t$  будет стоять 1. При  $t > k$  вектор  $H_t$  вычисляется рекуррентно:

$$H_t = \frac{\partial \sigma_t^2}{\partial \boldsymbol{\theta}} + 2 \sum_{j=1}^k \gamma_j \varepsilon_{t-j} \frac{d\varepsilon_{t-j}}{d\boldsymbol{\theta}} + \sum_{j=1}^l \delta_j H_{t-j}, \quad t = k+1, \dots, T.$$

Здесь  $\frac{\partial \sigma_t^2}{\partial \boldsymbol{\theta}}$  — непосредственная производная условной дисперсии по параметрам:

$$\frac{\partial \sigma_t^2}{\partial \boldsymbol{\theta}} = \left( \mathbf{0}^T, \quad 1, \quad \varepsilon_{t-1}^2, \dots, \varepsilon_{t-p}^2, \quad \sigma_{t-1}^2, \dots, \sigma_{t-q}^2, \quad \mathbf{0}^T \right).$$

Сверху в формуле подписаны параметры, по которым берется производная.

## Начальные приближения

В алгоритме большую роль играет выбор начальных приближений параметров  $\theta = \theta^0$ . Неправильный выбор может вызвать переполнение при вычислениях. Можно предложить следующие начальные приближения:

Для вектора коэффициентов регрессии  $\beta$  можно использовать оценки обычного метода наименьших квадратов:

$$\beta^0 = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}.$$

Затем на основе остатков из регрессии можно вычислить оценку безусловной дисперсии:

$$\hat{\sigma}^2 = \frac{1}{T} \sum_{t=1}^T \varepsilon_t^2.$$

Параметры  $\gamma_j^0$  и  $\delta_j^0$  выбираются положительными и такими, что

$$1 - \sum_{j=1}^k \gamma_j^0 - \sum_{j=1}^l \delta_j^0 > 0.$$

Можно взять, например,

$$\gamma_j^0 = \frac{1}{4k}, \quad \delta_j^0 = \frac{1}{4l} \quad (\text{при } l > 0).$$

Другой вариант — выбирать  $\gamma_j^0$  и  $\delta_j^0$  случайно.

Затем на основе оценки безусловной дисперсии и коэффициентов  $\gamma_j$  и  $\delta_j$  вычисляется начальное приближение для  $\mu$ :

$$\mu^0 = \hat{\sigma}^2 \left( 1 - \sum_{j=1}^k \gamma_j^0 - \sum_{j=1}^l \delta_j^0 \right)$$

В качестве начальных приближений параметров  $\eta_t$  можно взять оценку безусловной дисперсии:

$$\eta_t^0 = \hat{\sigma}^2.$$

## Алгоритм вычислений

Сначала вычисляются начальные приближения параметров. Следует следить, чтобы они оказались в допустимой области, т.е. вычисленные на их основе условные дисперсии все были положительными.

После этого идут итерации:

- ❖ Вычислить остатки  $\varepsilon_t(\theta) = y_t - X_t \beta$ .
- ❖ Вычислить условные дисперсии  $\sigma_t^2$  по рекуррентной формуле (2).
- ❖ Вычислить градиенты остатков  $d\varepsilon_t/d\theta$ .
- ❖ Вычислить градиенты условных дисперсий  $H_t$ .
- ❖ Вычислить  $\mathbf{Q}$ ,  $\mathbf{S}$ ,  $\xi$  и  $\mathbf{v}$ .
- ❖ Оценить искусственную регрессию и получить направление изменения параметров  $\Delta$ .
- ❖ Проверить выполнение правила остановки ( $R_{nc}^2 < \phi$ ).
- ❖ Выбрать коэффициент  $\lambda$  так, чтобы новое значение параметров  $\theta^{r+1} = \theta^r + \lambda \Delta^r$  оказалось в допустимой области и давало больший уровень функции правдоподобия, чем  $\theta^r$ , т.е.  $\ell(\theta^{r+1}) > \ell(\theta^r)$ .
- ❖ Начать новую итерацию.

После того, как итеративный алгоритм сойдется, на основе ковариационной матрицы из искусственной регрессии вычисляются стандартные ошибки параметров и t-статистики по обычным формулам.