Прикладной статистический анализ данных. 11. Анализ временных рядов, часть вторая.

Рябенко Евгений
riabenko.e@gmail.com

21 ноября 2014 г.

Прогнозирование временного ряда

Временной ряд: $y_1, \ldots, y_T, \ldots, \quad y_t \in \mathbb{R}$, — значения признака, измеренные через постоянные временные интервалы.

Задача прогнозирования — найти функцию f_T:

$$y_{T+d} \approx f_T\left(y_T, \ldots, y_1, d\right) \equiv \hat{y}_{T+d|T},$$

где $d \in \{1, 2, \ldots, D\}$ — отсрочка прогноза, D — горизонт прогнозирования.

Стационарность

Ряд $y_1, \ldots, y_T$ **стационарен**, если $\forall s$ распределение $y_t, \ldots, y_{t+s}$ не зависит от t, т. е. его свойства не зависят от времени.

Ряды с трендом или сезонностью нестационарны.

Ряды с непериодическими циклами стационарны, поскольку нельзя предсказать заранее, где будут находится максимумы и минимумы.

Стационарность

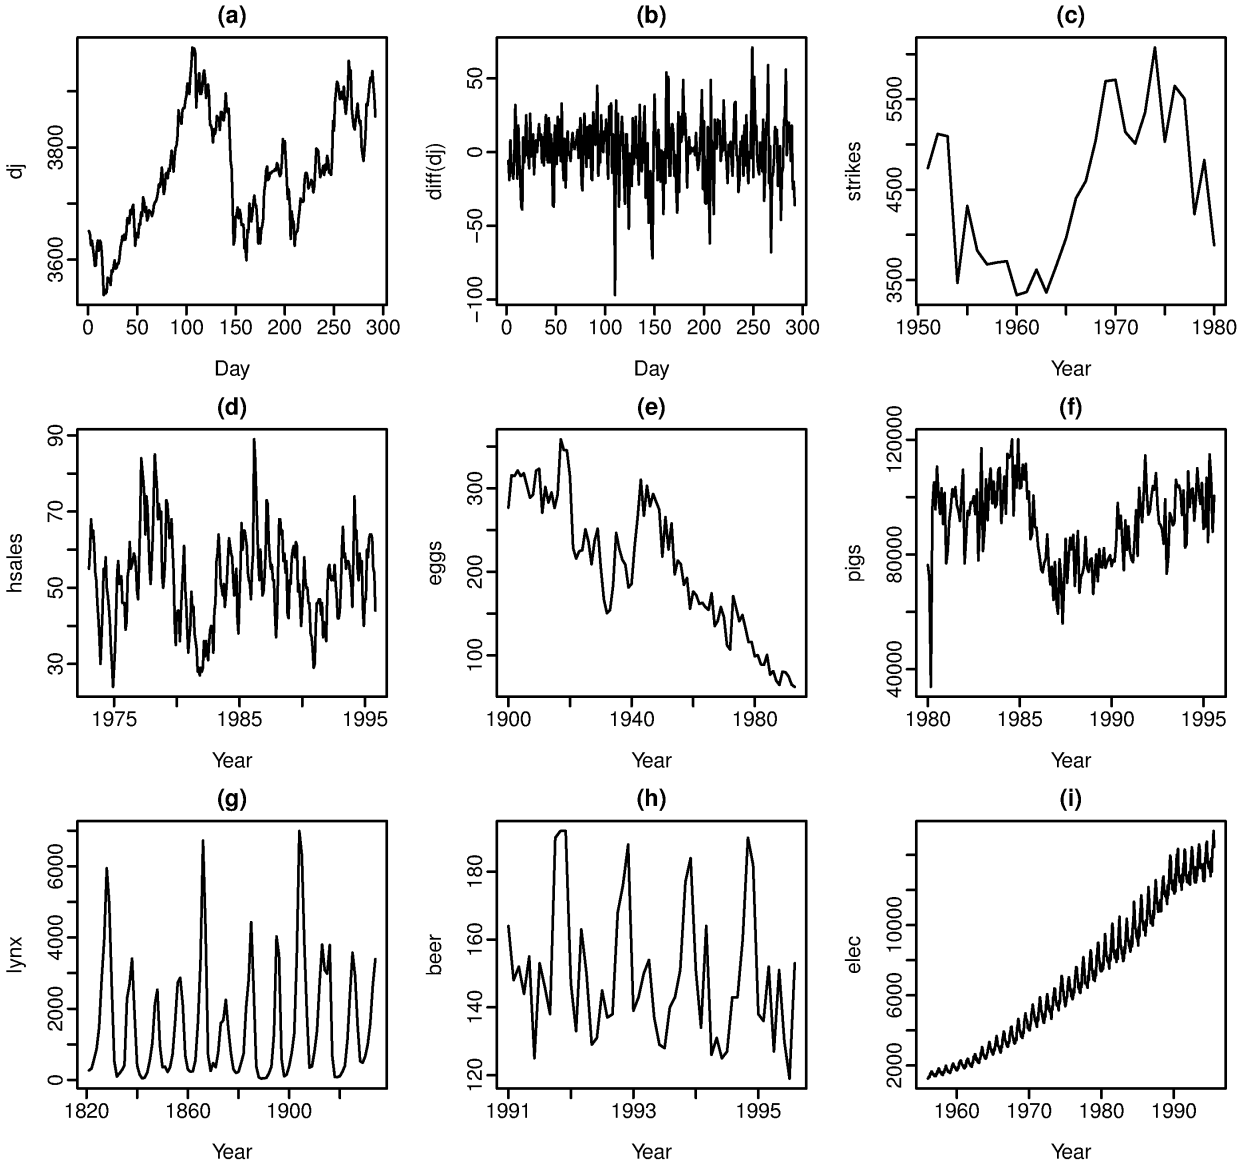

Стационарность

Нестационарны из-за сезонности:

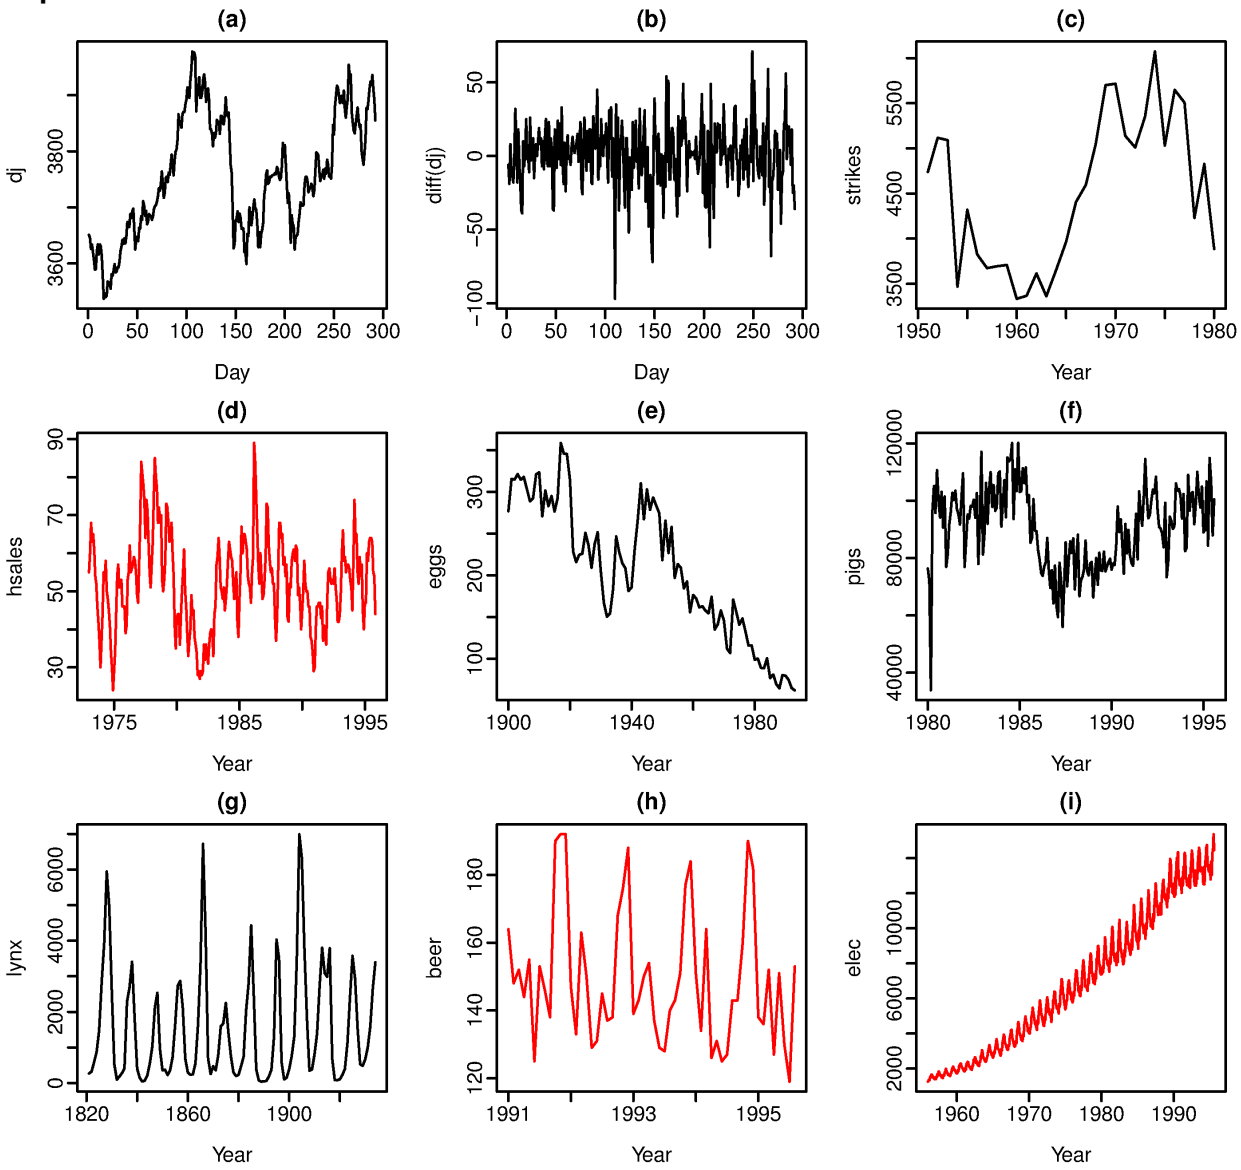

Стационарность

Нестационарны из-за тренда:

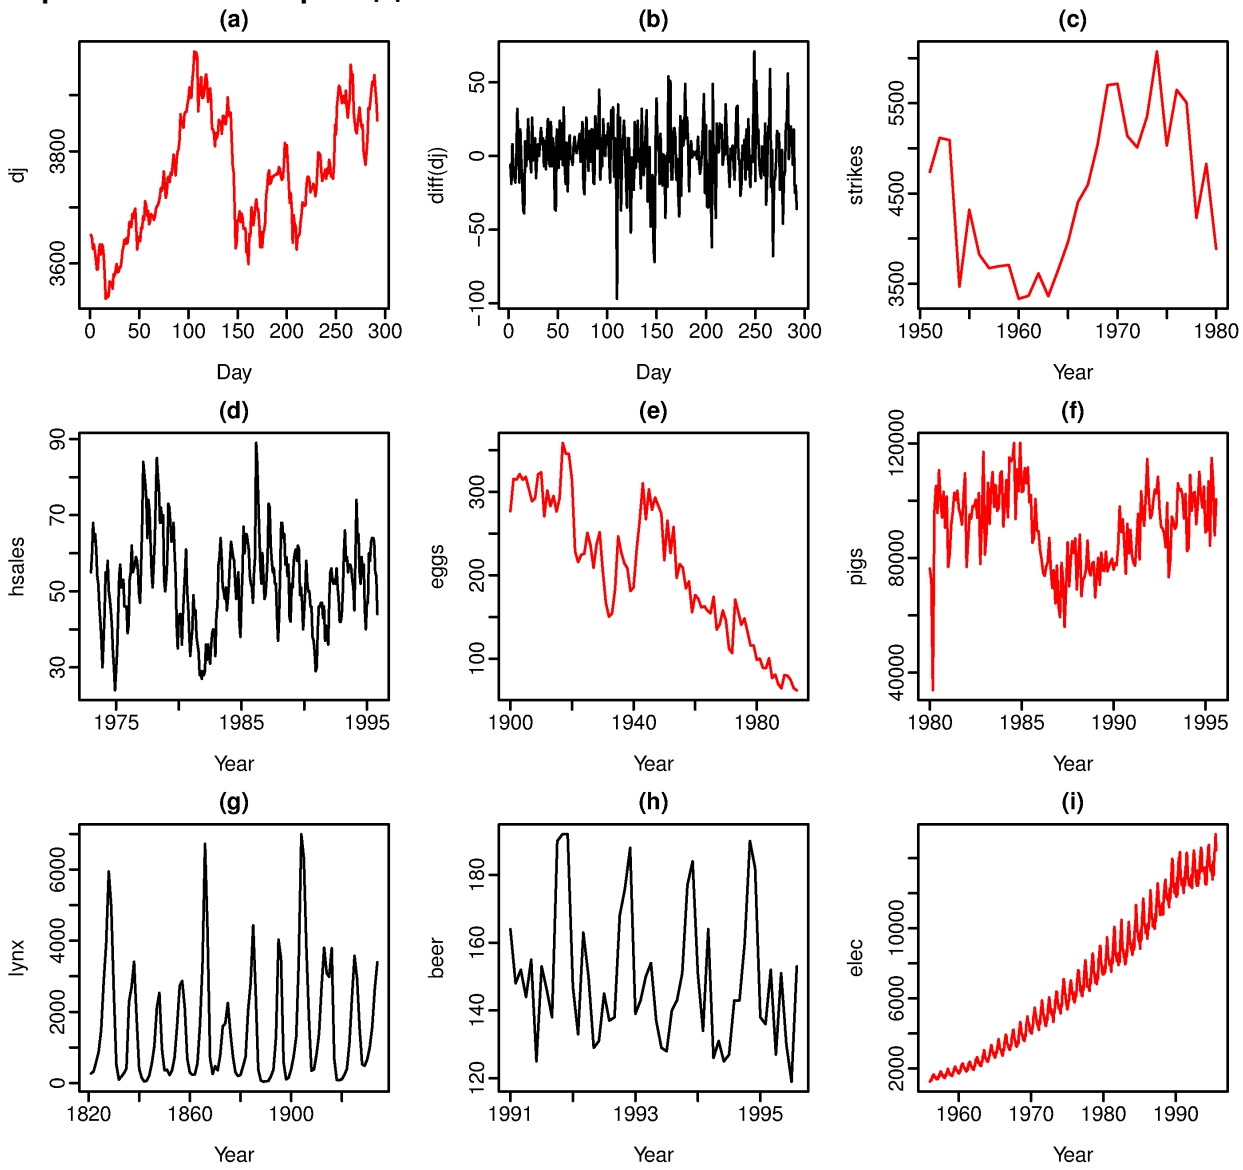

Стационарность

Нестационарны из-за меняющейся дисперсии:

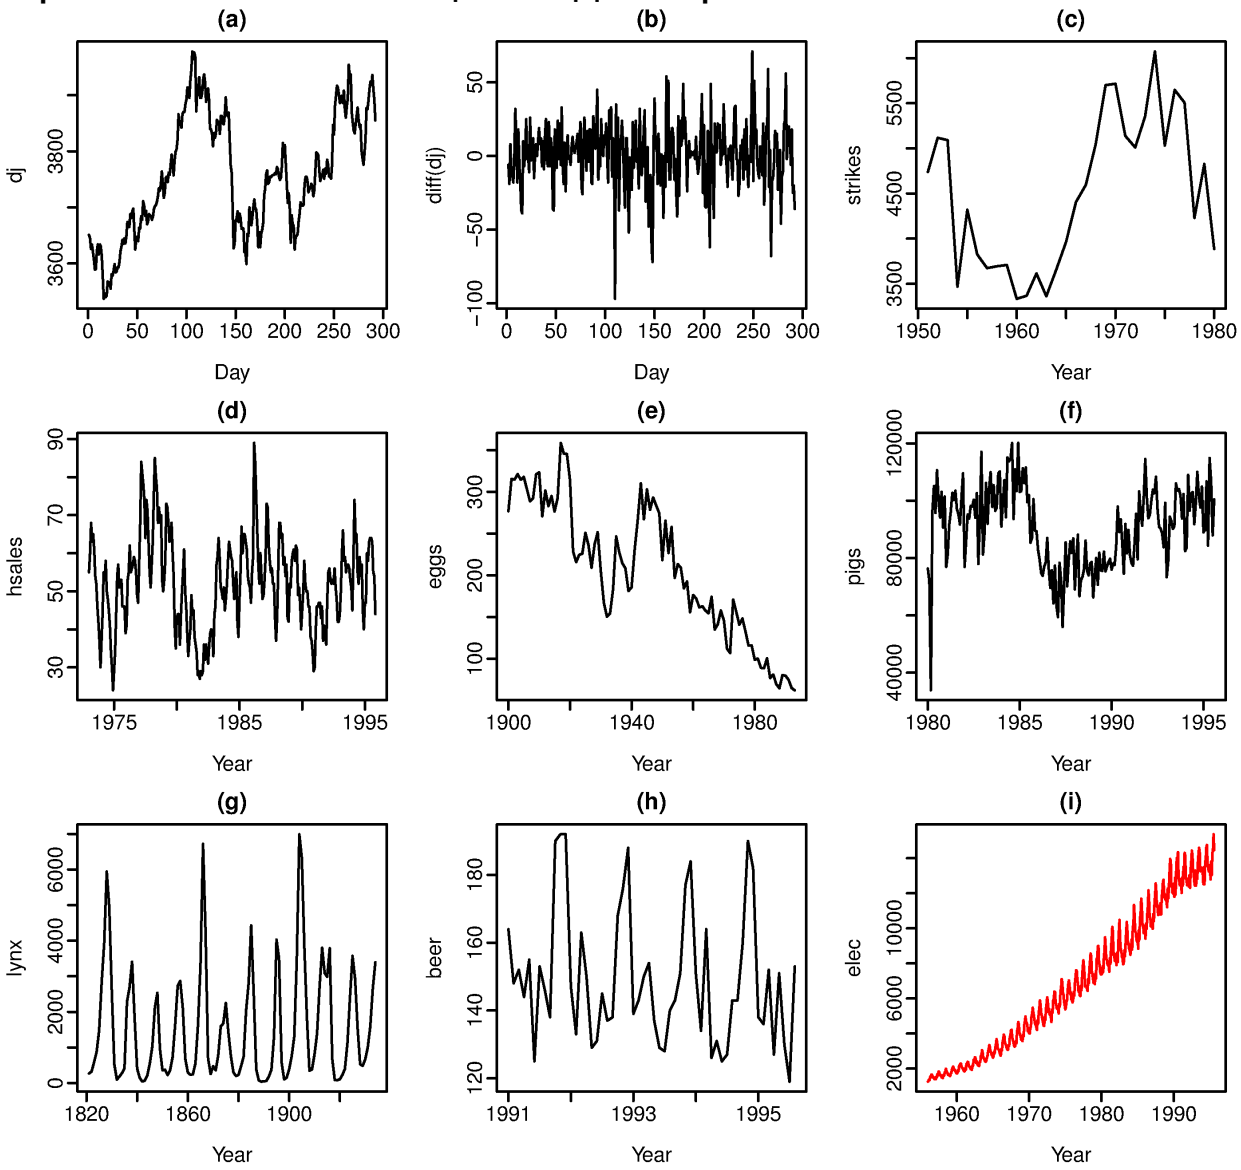

Стационарность

Стационарны:

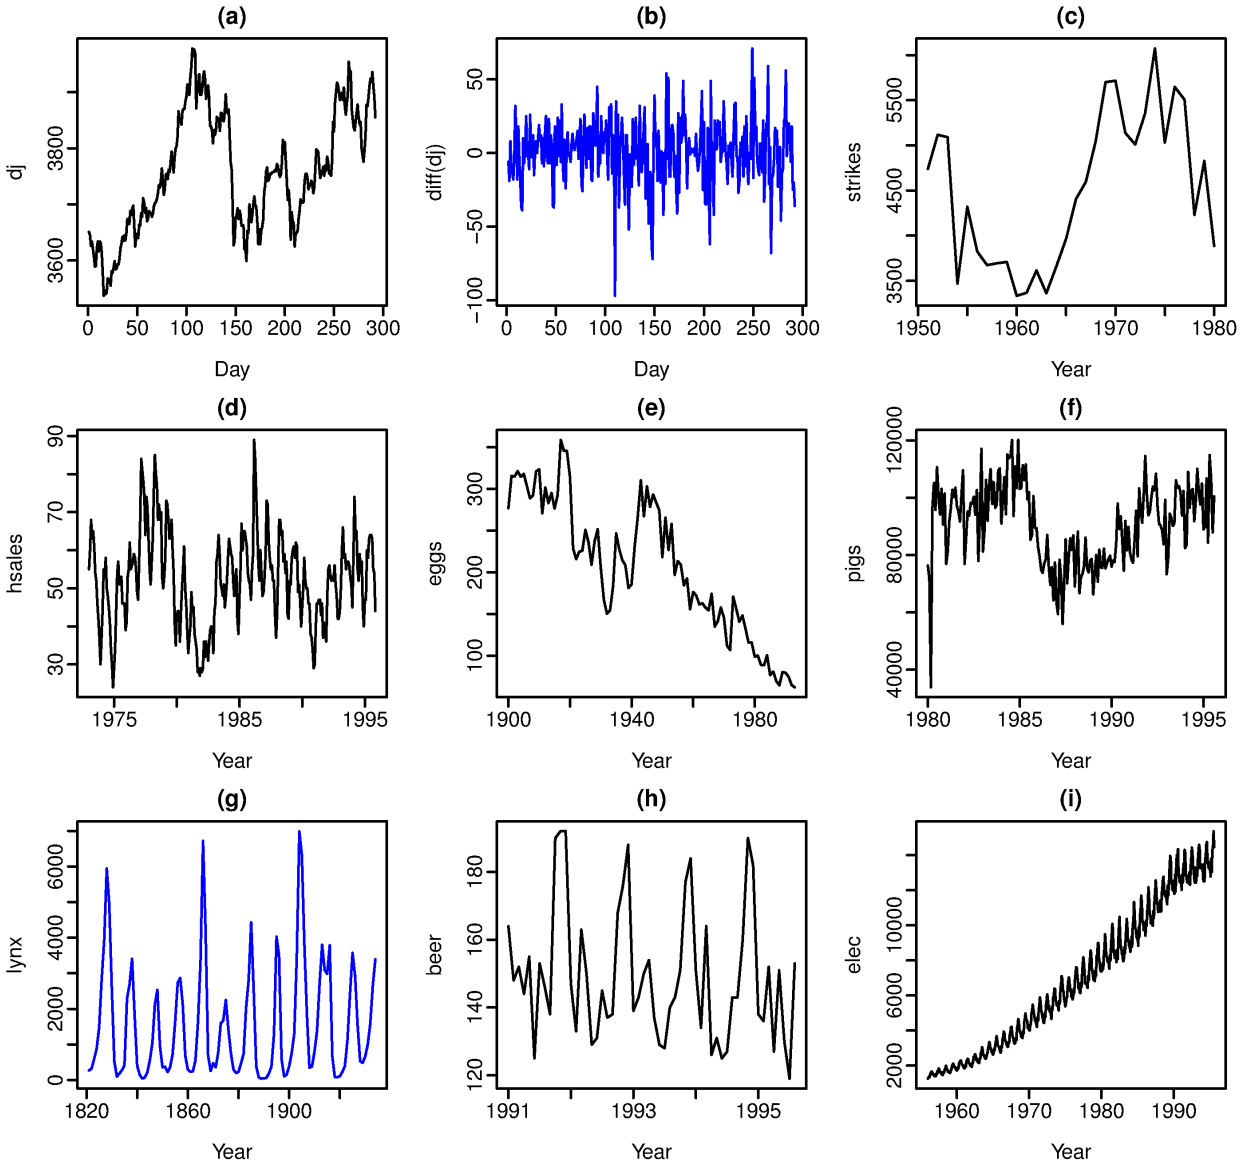

Стабилизация дисперсии

Для рядов с монотонно меняющейся дисперсией можно использовать стабилизирующие преобразования.

Часто используют логарифмирование:

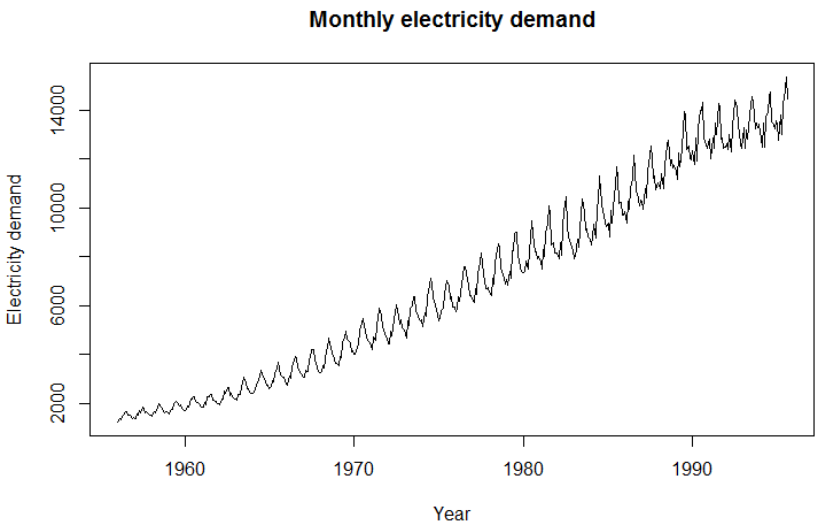

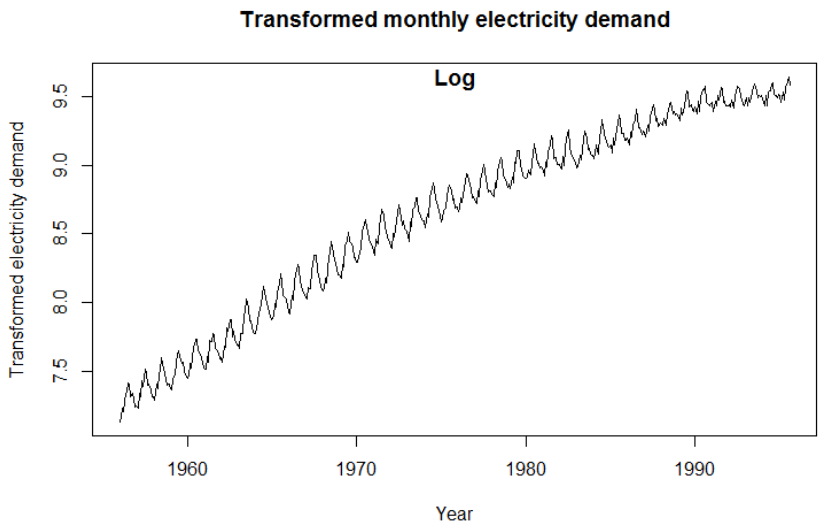

Преобразования Бокса-Кокса

Параметрическое семейство стабилизирующих дисперсию преобразований:

$$y'_t = \begin{cases} \ln y_t, & \lambda = 0, \\ \left(y_t^\lambda - 1\right)/\lambda, & \lambda \neq 0. \end{cases}$$

Параметр λ выбирается так, чтобы минимизировать дисперсию или максимизировать правдоподобие модели.

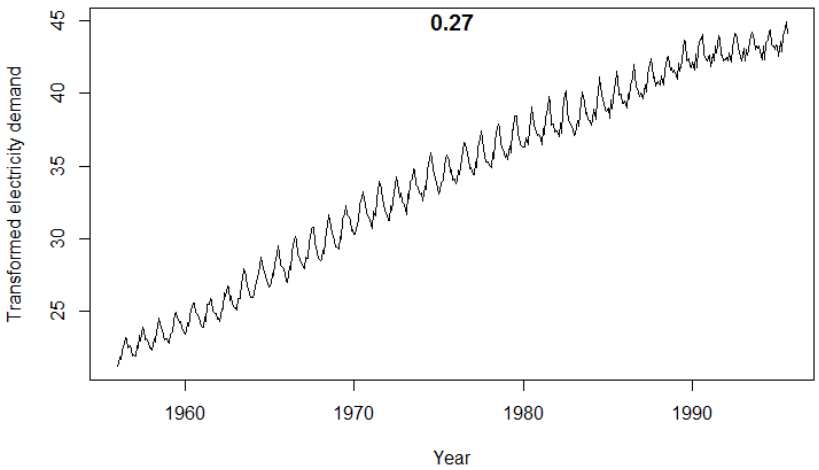

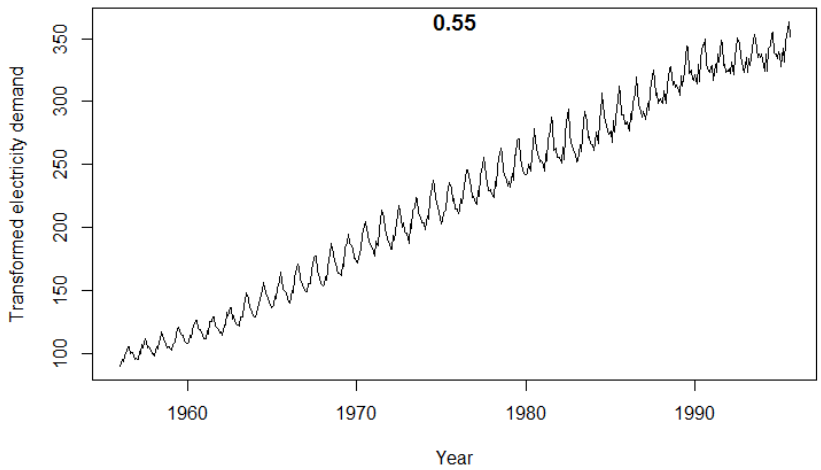

Преобразования Бокса-Кокса

После построения прогноза для трансформированного ряда его нужно преобразовать в прогноз исходного:

$$\hat{y}_t = \begin{cases} \exp\left(\hat{y}'_t\right), & \lambda = 0, \\ \left(\lambda \hat{y}'_t + 1\right)^{1/\lambda}, & \lambda \neq 0. \end{cases}$$

- Если некоторые $y_t \leq 0$, преобразования Бокса-Кокса невозможны (нужно прибавить к ряду константу).
- Часто оказывается, что преобразование вообще не нужно.
- Стоит округлять значение λ, чтобы упростить интерпретацию.
- Как правило, стабилизирующее преобразование слабо влияет на прогноз и сильно — на предсказательный интервал.

Дифференцирование

Дифференцирование ряда — переход к попарным разностям его соседних значений:

$$y_1, \ldots, y_T \longrightarrow y'_2, \ldots, y'_T,$$

$$y'_t = y_t - y_{t-1}.$$

Дифференцированием можно стабилизировать среднее значение ряда и избавиться от тренда и сезонности.

Может применяться неоднократное дифференцирование; например, для второго порядка:

$$y_1, \ldots, y_T \longrightarrow y'_2, \ldots, y'_T \longrightarrow y''_3, \ldots, y''_T,$$

$$y''_t = y'_t - y'_{t-1} = y_t - 2y_{t-1} + y_{t-2}.$$

Дифференцирование

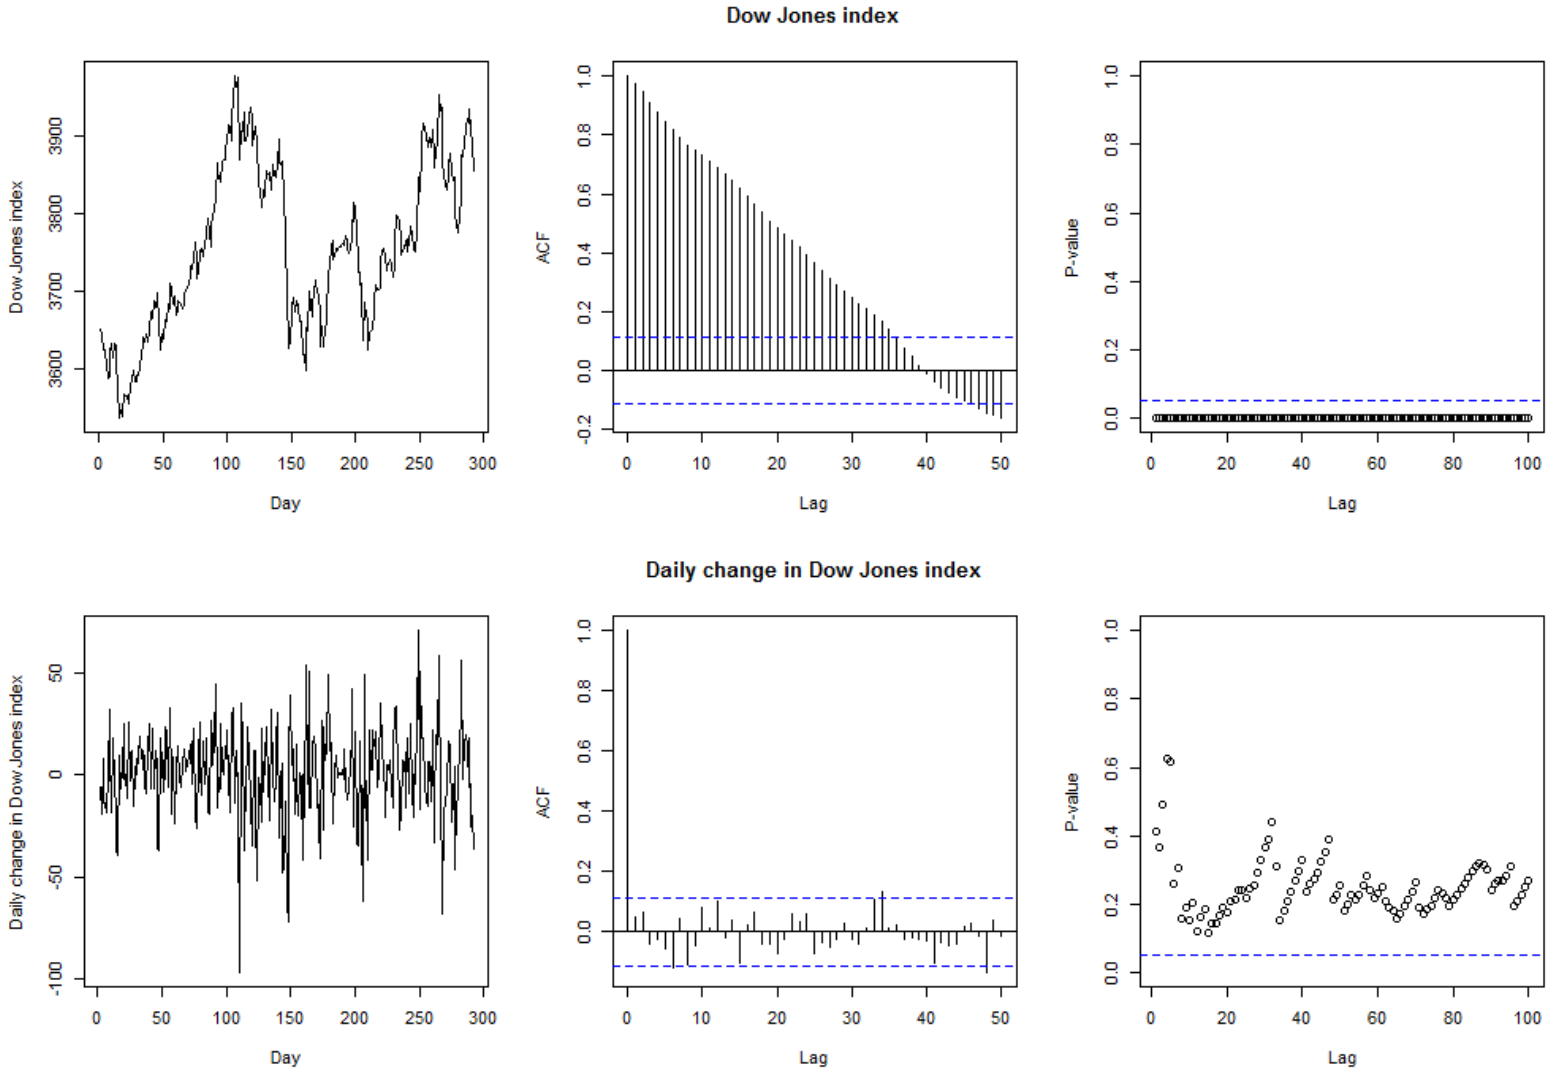

Критерий KPSS: для исходного ряда $p < 0.01$, для ряда первых разностей — $p > 0.1$.

Сезонное дифференцирование

Сезонное дифференцирование ряда — переход к попарным разностям его значений в соседних сезонах:

$$y_1, \ldots, y_T \longrightarrow y'_{s+1}, \ldots, y'_T,$$

$$y'_t = y_t - y_{t-s}.$$

Сезонное дифференцирование

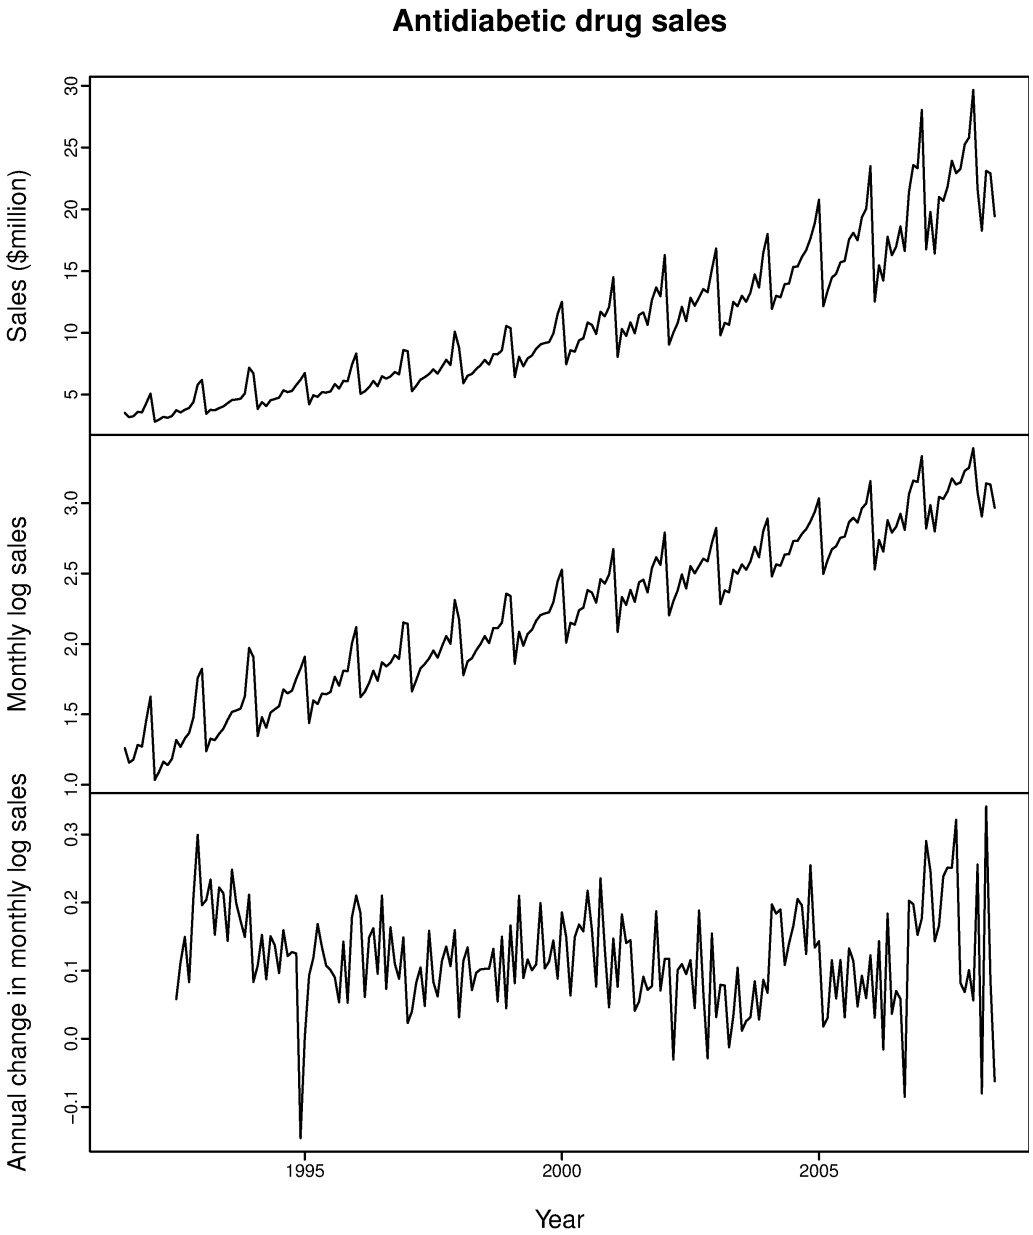

Критерий KPSS: для исходного ряда $p < 0.01$, для логарифмированного — $p < 0.01$, после сезонного дифференцирования — $p > 0.1$.

Комбинированное дифференцирование

Сезонное и обычное дифференцирование может применяться к одному ряду в любом порядке.

Если ряд имеет выраженный сезонный профиль, рекомендуется начинать с сезонного дифференцирования — после него ряд уже может оказаться стационарным.

Комбинированное дифференцирование

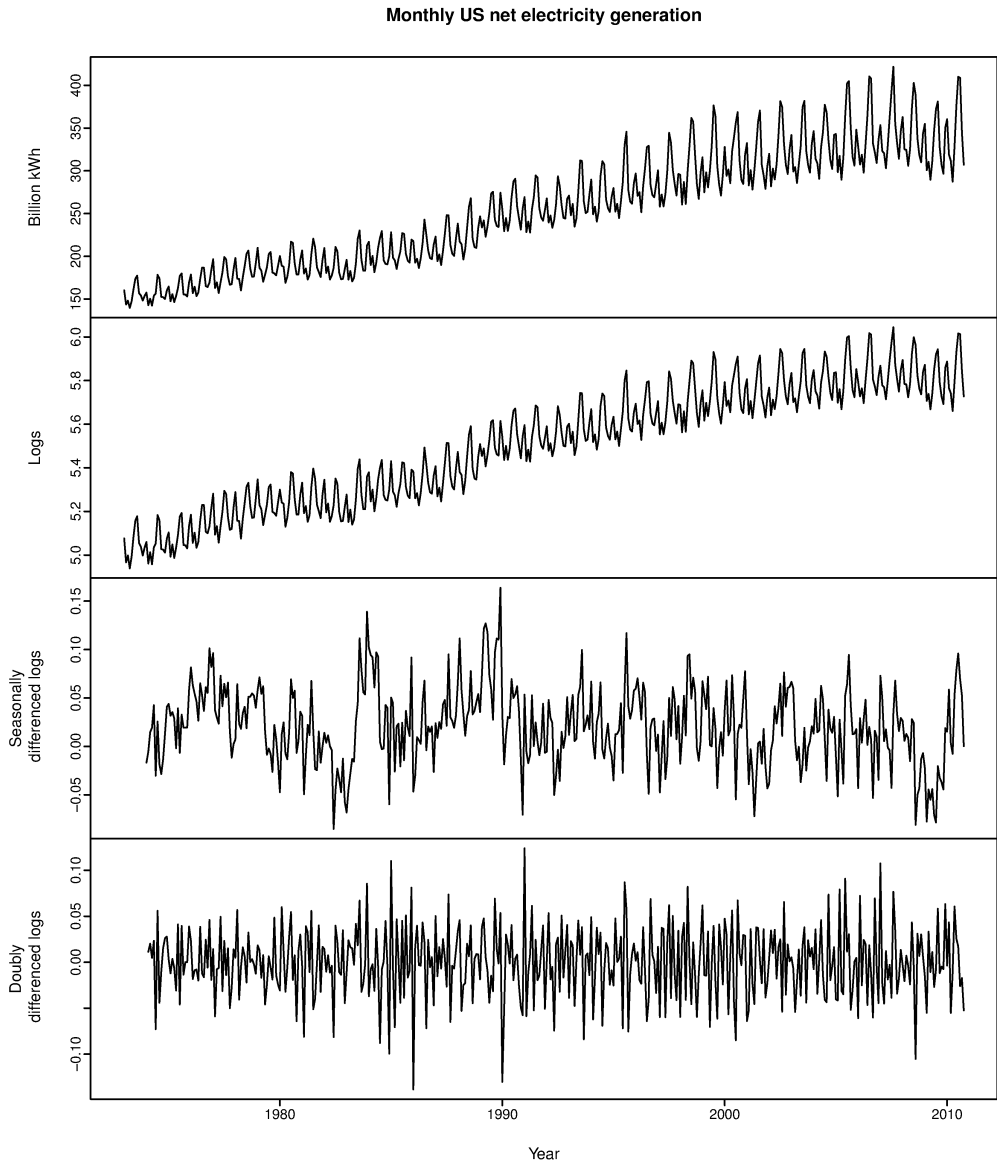

Критерий KPSS: для исходного ряда $p < 0.01$, для логарифмированного — $p < 0.01$, после сезонного дифференцирования — $p = 0.0355$,
после ещё одного дифференцирования — $p > 0.1$.

Авторегрессия

$$AR(p): \quad y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \cdots + \phi_p y_{t-p} + \varepsilon_t,$$

где y_t — стационарный ряд с нулевым средним, $\phi_1, \ldots, \phi_p$ — константы ($\phi_p \neq 0$), ε_t — гауссов белый шум с нулевым средним и постоянной дисперсией σ_ε^2.

Если среднее равно μ, модель принимает вид

$$y_t = \alpha + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \cdots + \phi_p y_{t-p} + \varepsilon_t,$$

где $\alpha = \mu\left(1 - \phi_1 - \cdots - \phi_p\right)$.

Другой способ записи:

$$\phi(B)\, y_t = \left(1 - \phi_1 B - \phi_2 B^2 - \cdots - \phi_p B^p\right) y_t = \varepsilon_t,$$

где B — разностный оператор ($By_t = y_{t-1}$).

Линейная комбинация p подряд идущих членов ряда даёт белый шум.

Авторегрессия

Чтобы ряд AR(p) был стационарным, должны выполняться ограничения на коэффициенты. Например,

- в AR(1) необходимо $-1 < \phi_1 < 1$;
- в AR(2) необходимо $-1 < \phi_2 < 1,\ \phi_1 + \phi_2 < 1,\ \phi_2 - \phi_1 < 1$.

С ростом p вид ограничений усложняется.

Скользящее среднее

$$MA(q): \quad y_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \cdots + \theta_q \varepsilon_{t-q},$$

где y_t — стационарный ряд с нулевым средним, $\theta_1, \ldots, \theta_q$ — константы ($\theta_q \neq 0$), ε_t — гауссов белый шум с нулевым средним и постоянной дисперсией σ_ε^2.

Если среднее равно μ, модель принимает вид

$$y_t = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \cdots + \theta_q \varepsilon_{t-q}.$$

Другой способ записи:

$$y_t = \theta(B)\,\varepsilon_t = \left(1 + \theta_1 B + \theta_2 B^2 + \cdots + \theta_q B^q\right)\varepsilon_t,$$

где B — разностный оператор.

Линейная комбинация q подряд идущих компонент белого шума ε_t даёт элемент ряда.

Скользящее среднее

Чтобы ряд модель MA(q) была обратимой, должны выполняться ограничения на коэффициенты. Например,

- в MA(1) необходимо $-1 < \theta_1 < 1$;
- в MA(2) необходимо $-1 < \theta_2 < 1,\ \theta_1 + \theta_2 > -1,\ \theta_1 - \theta_2 < 1$.

С ростом q вид ограничений усложняется.

ARMA (Autogerressive moving average)

$$ARMA(p,q): \quad y_t = \phi_1 y_{t-1} + \cdots + \phi_p y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \cdots + \theta_q \varepsilon_{t-q},$$

где y_t — стационарный ряд с нулевым средним, $\phi_1, \ldots, \phi_p, \theta_1, \ldots, \theta_q$ — константы ($\phi_p \neq 0$, $\theta_q \neq 0$), ε_t — гауссов белый шум с нулевым средним и постоянной дисперсией σ_ε^2.

Если среднее равно μ, модель принимает вид

$$y_t = \alpha + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \cdots + \phi_p y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \cdots + \theta_q \varepsilon_{t-q},$$

где $\alpha = \mu \left(1 - \phi_1 - \cdots - \phi_p\right)$.

Другой способ записи:

$$\phi(B)\, y_t = \theta(B)\, \varepsilon_t.$$

Согласно теорема Вольда, любой стационарный ряд может быть аппроксимирован моделью ARMA(p,q).

ARIMA (Autogerressive integrated moving average)[1]

Ряд описывается моделью $ARIMA(p, d, q)$, если ряд его разностей

$$\nabla^d y_t = (1 - B)^d y_t$$

описывается моделью $ARMA(p, q)$.

$$\phi(B) \nabla^d y_t = \theta(B) \varepsilon_t.$$

[1] Также это энергетическое имя, данное творцом первозданным двум своим посланникам для работы планете Земля, подробности см. http://light-love.ru/nasha-istoriya/ot-avtorov.html/

Частичная автокорреляционная функция

Частичная автокорреляция стационарного ряда y_t:

$$\phi_{hh} = \begin{cases} r\left(y_{t+1}, y_t\right), & h = 1, \\ r\left(y_{t+h} - y_{t+h}^{h-1}, y_t - y_t^{h-1}\right), & h \geq 2, \end{cases}$$

где y_t^{h-1} — регрессия y_t на $y_{t+1}, y_{t+2}, \ldots, y_{t+h-1}$:

$$y_t^{h-1} = \beta_1 y_{t+1} + \beta_2 y_{t+2} + \cdots + \beta_{h-1} y_{t+h-1},$$
$$y_{t+h}^{h-1} = \beta_1 y_{t+h-1} + \beta_2 y_{t+h-2} + \cdots + \beta_{h-1} y_{t+1}.$$

Оценка параметров модели

- При заданных p, d, q коэффициенты модели оцениваются методом максимального правдоподобия; функционал качества — логарифм правдоподобия LL.
- d выбирается так, чтобы ряд был стационарным.
- p и q нельзя выбирать из принципа максимума правдоподобия: LL всегда увеличивается с ростом p и q.
- При выборе p и q погут помочь автокорреляционные функции ACF и PACF:
  - в модели $ARIMA(p, d, 0)$ ACF экспоненциально затухает или имеет синусоидальный вид, а PACF значимо отличается от нуля при лаге p;
  - в модели $ARIMA(0, d, q)$ PACF экспоненциально затухает или имеет синусоидальный вид, а ACF значимо отличается от нуля при лаге q.

Информационные критерии

AIC — информационный критерий Акаике:

$$AIC = -2LL + 2\left(p + q + k + 1\right),$$

где $k = 1$ при $c \neq 0$ и $k = 0$ при $c = 0$;

$AICc$ — он же с поправкой на случай небольшого размера выборки:

$$AICc = -2LL + \frac{2\left(p + q + k + 1\right)\left(p + q + k + 2\right)}{T - p - q - k - 2};$$

BIC (SIC) — байесовский (Шварца) информационный критерий:

$$BIC = -2LL + \left(\log T - 2\right)\left(p + q + k + 1\right).$$

Прогнозирование с помощью ARIMA

1. Строится график ряда, идентифицируются необычные значения.
2. При необходимости делается стабилизирующее дисперсию преобразование.
3. Если ряд нестационарен, подбирается порядок дифференцирования.
4. Анализируются ACF/PACF, чтобы понять, можно ли использовать модели AR(p)/MA(q).
5. Обучаются модели-кандидаты, сравнивается их AICc.
6. Остатки полученной модели исследуются на несмещённость, стационарность и неавтокоррелированность; если предположения не выполняются, исследуются модификации модели.
7. В финальной модели t заменяется на $T + h$, будущие наблюдения — на их прогнозы, будущие ошибки — на нули, прошлые ошибки — на остатки.

Построение предсказательного интервала

Если остатки модели нормальны и гомоскедастичны, предсказательные интервалы определяются теоретически.
Например, для прогноза на следующую точку предсказательный интервал — $\hat{y}_{T+1|T} \pm 1.96\hat{\sigma}_\varepsilon$.

Если нормальность или гомоскедастичность не выполняется, предсказательные интервалы генерируются с помощью симуляции.

Seasonal multiplicative ARMA/ARIMA

$$ARMA(p,q)\times(P,Q)_s: \quad \Phi_P\left(B^s\right)\phi\left(B\right)y_t=\alpha+\Theta_Q\left(B^s\right)\theta\left(B\right)\varepsilon_t,$$

где

$$\Phi_P\left(B^s\right)=1-\Phi_1B^s-\Phi_2B^{2s}-\cdots-\Phi_PB^{Ps},$$
$$\Theta_Q\left(B^s\right)=1+\Theta_1B^s+\Theta_2B^{2s}+\cdots+\Theta_QB^{Ps}.$$

SARIMA:

$$\Phi_P\left(B^s\right)\phi\left(B\right)\nabla_s^D\nabla^dy_t=\alpha+\Theta_Q\left(B^s\right)\theta\left(B\right)\varepsilon_t.$$

Объём продаж кортекостероидов в Австралии

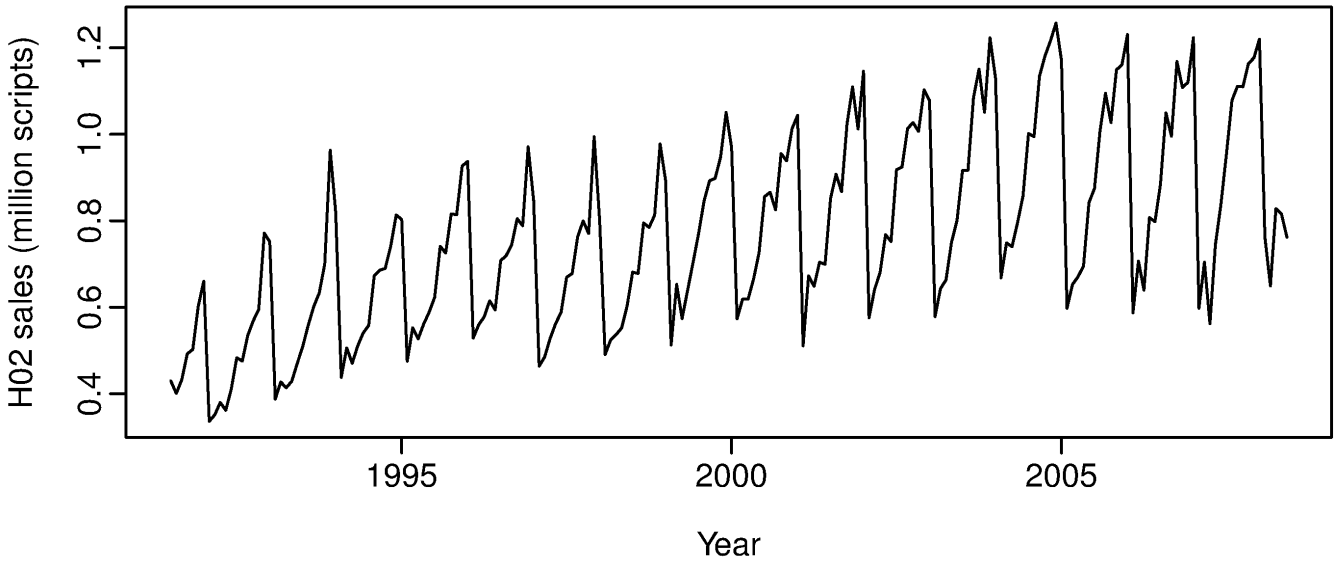

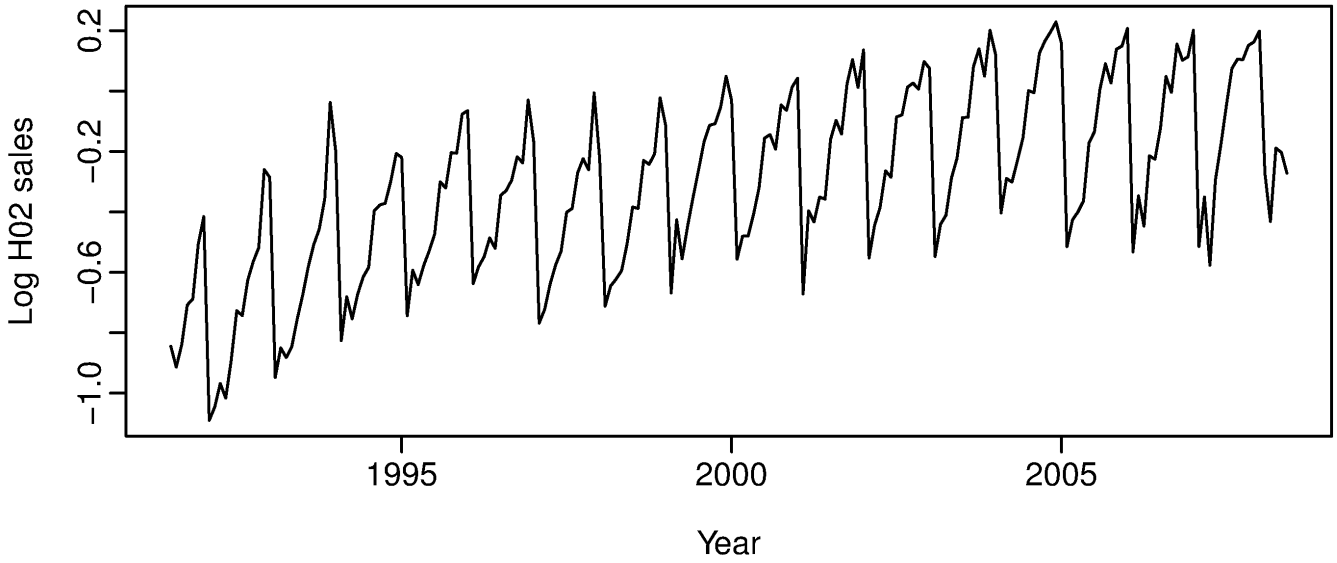

Сезонное дифференцирование

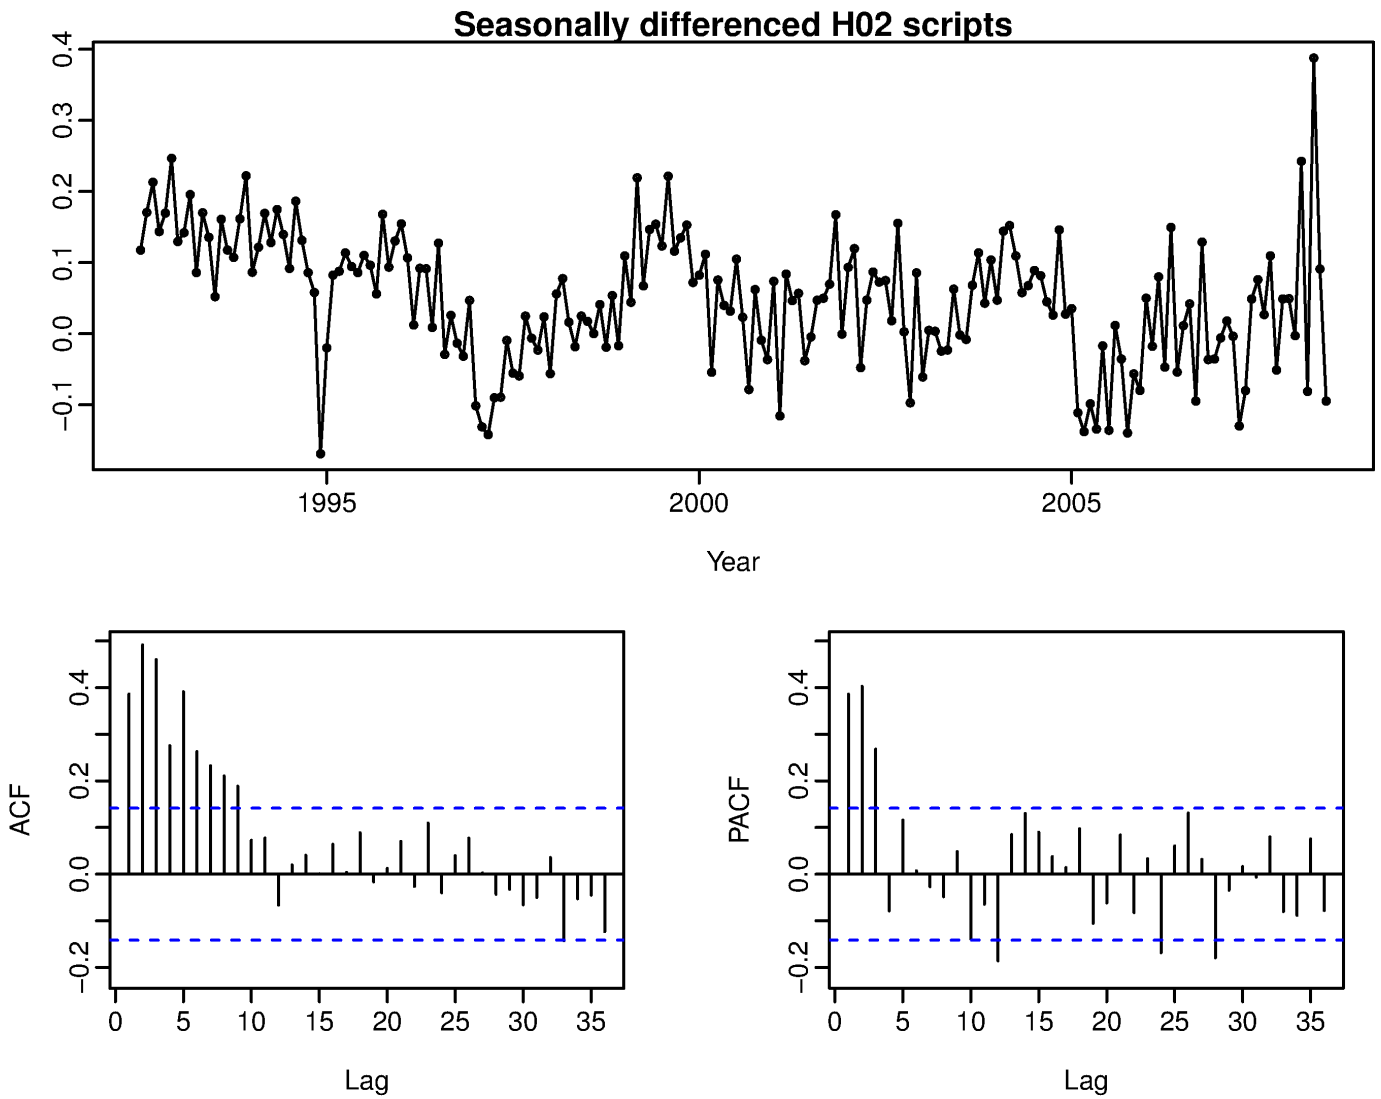

На PACF значимы лаги 1-3, 12, 24. Начнём с модели ARIMA(3,0,0)(2,1,0)$_{12}$.

Сравнение моделей

	$AICc$
ARIMA(3,0,0)(2,1,0)$_{12}$	-475.12
ARIMA(3,0,1)(2,1,0)$_{12}$	-476.31
ARIMA(3,0,2)(2,1,0)$_{12}$	-474.88
ARIMA(3,0,1)(1,1,0)$_{12}$	-463.40
ARIMA(3,0,1)(0,1,1)$_{12}$	-483.67
ARIMA(3,0,1)(0,1,2)$_{12}$	-485.48
ARIMA(3,0,1)(1,1,1)$_{12}$	-484.25

Лучшая из рассматриваемых моделей — ARIMA(3,0,1)(0,1,2)$_{12}$.

Остатки ARIMA(3,0,1)(0,1,2)$_{12}$

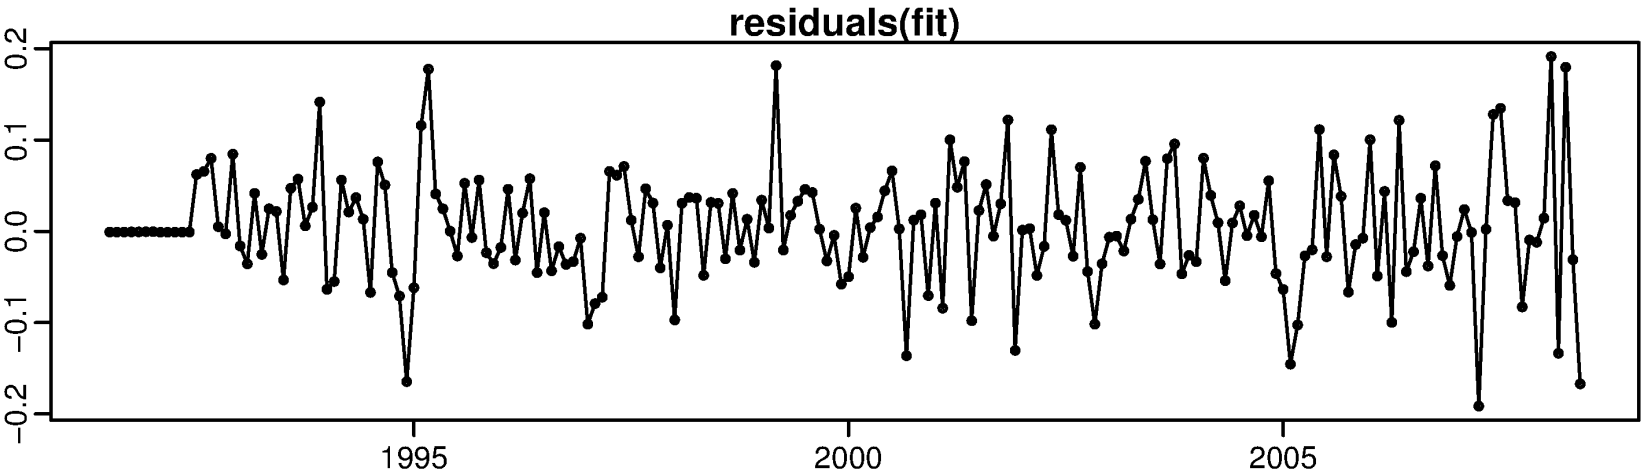

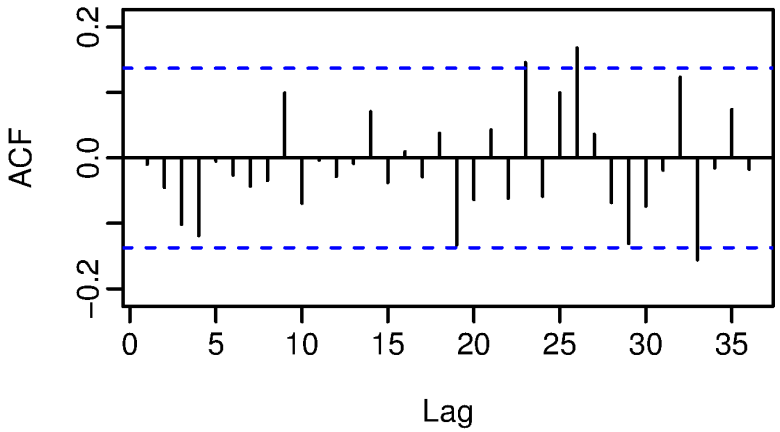

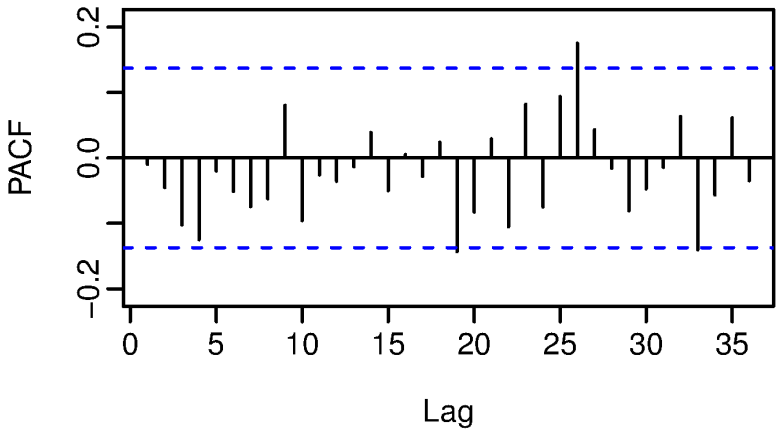

На ACF и PACF есть значимые лаги.

Остатки ARIMA(3,0,1)(0,1,2)$_{12}$

Критерий Льюнга-Бокса:

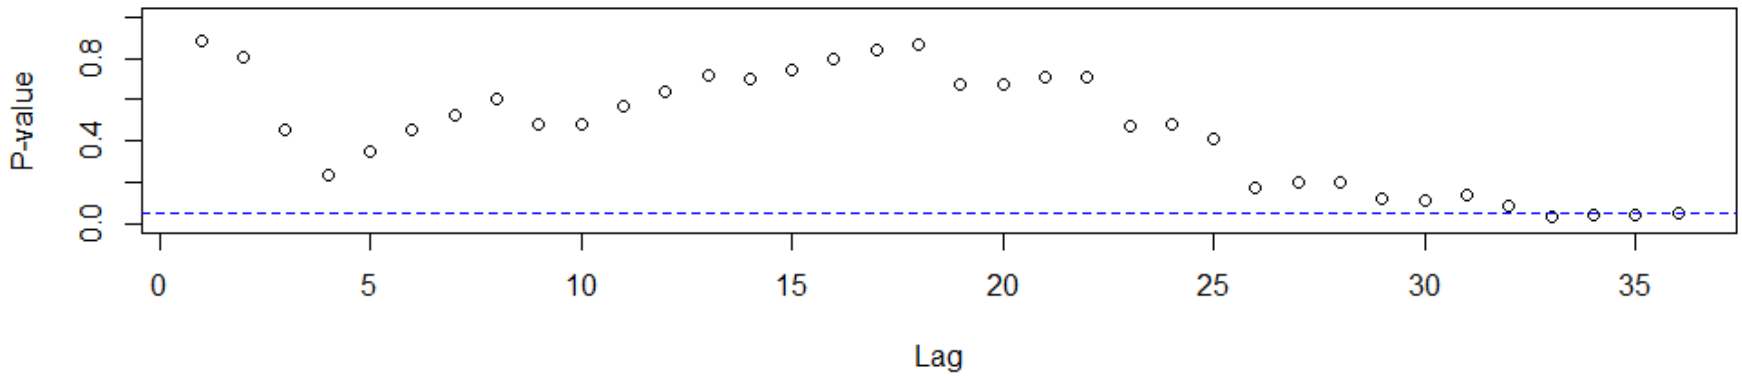

Критерий стационарности KPSS: $p > 0.1$.
Критерий нормальности Шапиро-Уилка: $p = 0.01079$.
Критерий Уилкоксона: $p = 0.3143$.
Критерий гомоскедастичности Бройша-Пагана: $p = 0.001723$.

Прогноз ARIMA(3,0,1)(0,1,2)$_{12}$

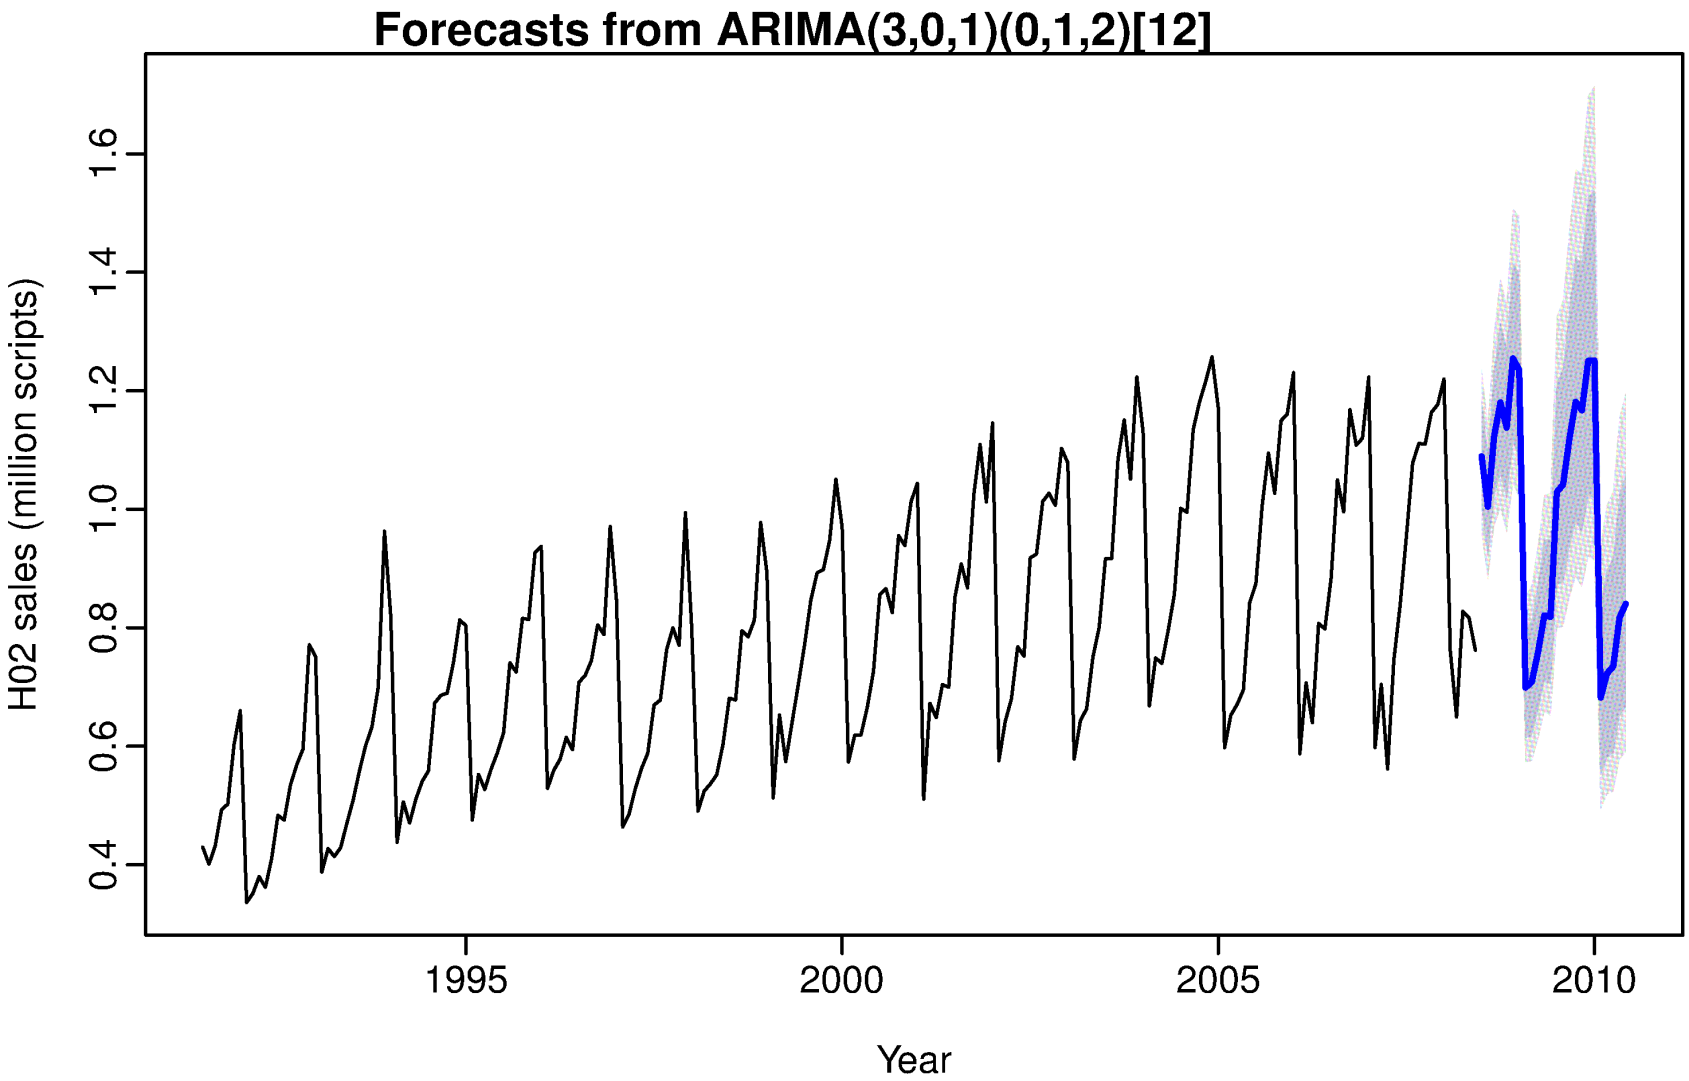

auto.arima

```
auto.arima(x, d=NA, D=NA, max.p=5, max.q=5,
    max.P=2, max.Q=2, max.order=5, max.d=2, max.D=1,
    start.p=2, start.q=2, start.P=1, start.Q=1,
    stationary=FALSE, seasonal=TRUE,
    ic=c("aicc","aic", "bic"), stepwise=TRUE, trace=FALSE,
    approximation=(length(x)>100 | frequency(x)>12), xreg=NULL,
    test=c("kpss","adf","pp"), seasonal.test=c("ocsb","ch"),
    allowdrift=TRUE, lambda=NULL, parallel=FALSE, num.cores=2)
```

auto.arima

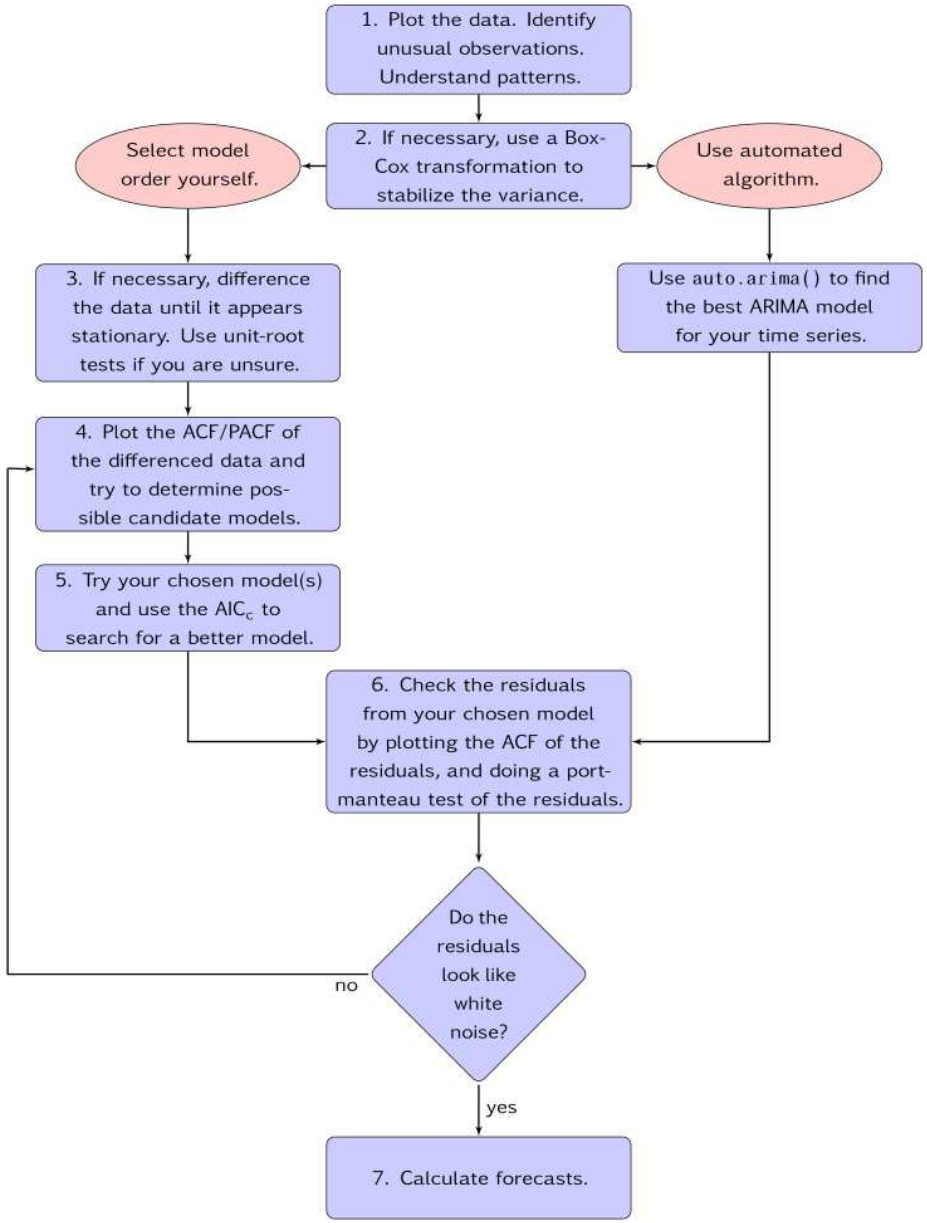
1. Plot the data. Identify unusual observations. Understand patterns.
2. If necessary, use a Box-Cox transformation to stabilize the variance.
Select model order yourself.
Use automated algorithm.
3. If necessary, difference the data until it appears stationary. Use unit-root tests if you are unsure.
Use auto.arima() to find the best ARIMA model for your time series.
4. Plot the ACF/PACF of the differenced data and try to determine possible candidate models.
5. Try your chosen model(s) and use the AIC$_c$ to search for a better model.
6. Check the residuals from your chosen model by plotting the ACF of the residuals, and doing a portmanteau test of the residuals.
Do the residuals look like white noise?
no
yes
7. Calculate forecasts.

auto.arima

В автоматическом режиме подбирается модель ARIMA(3,1,3)$(0,1,1)_{12}$; её остатки:

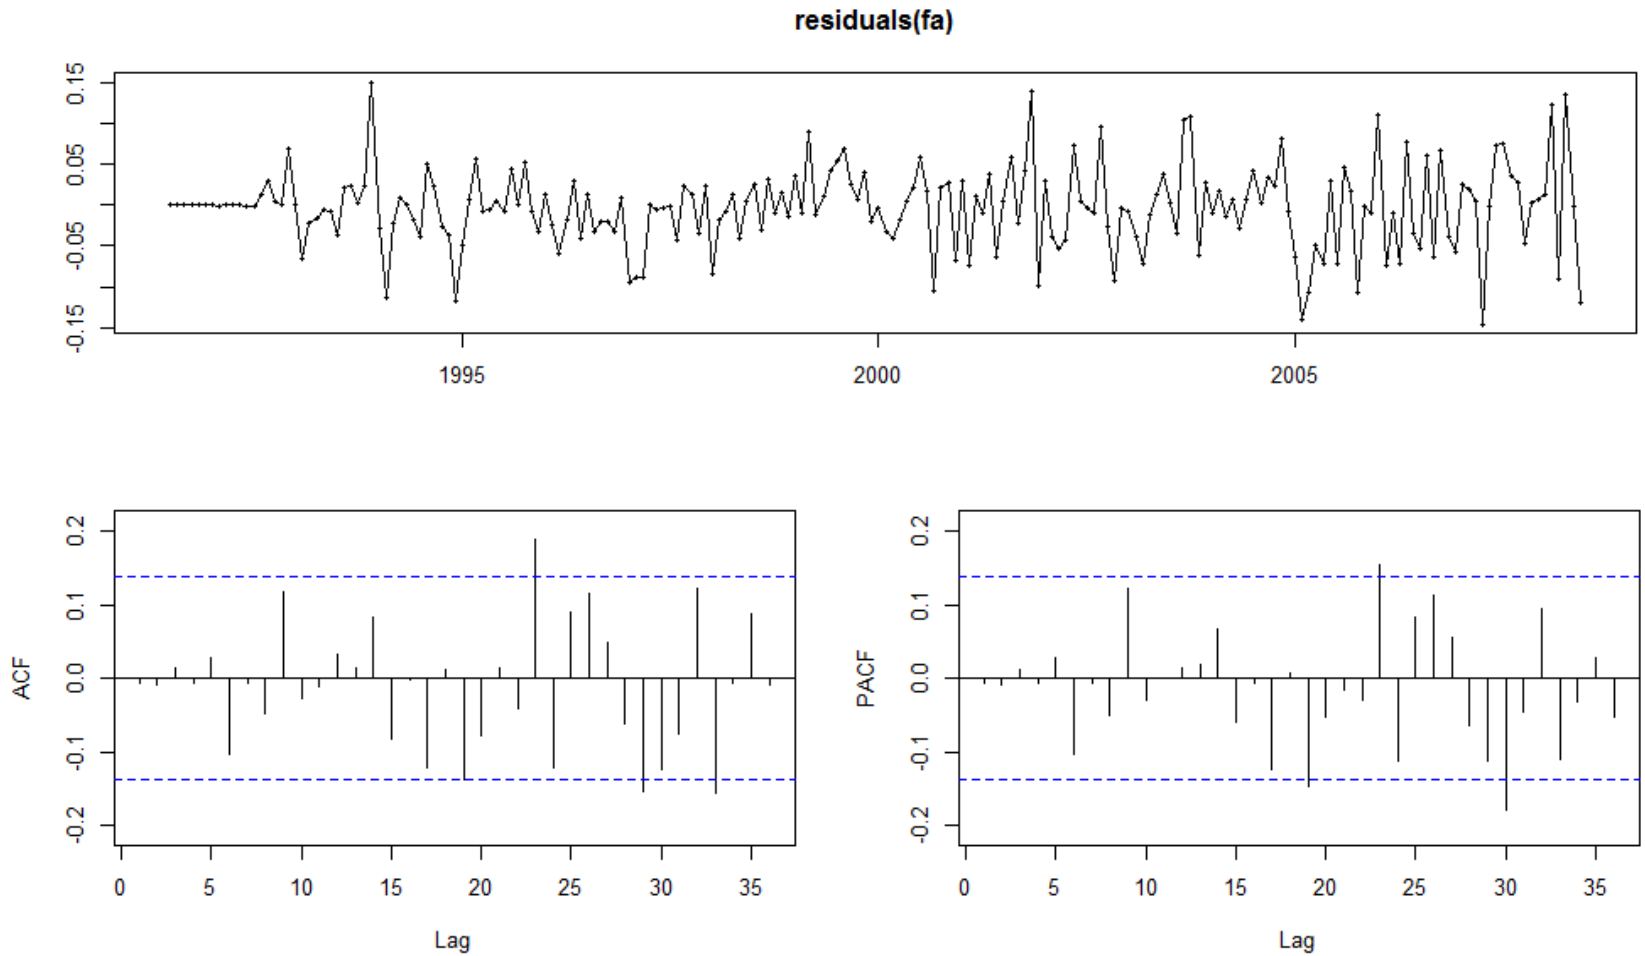

auto.arima

Критерий Льюнга-Бокса:

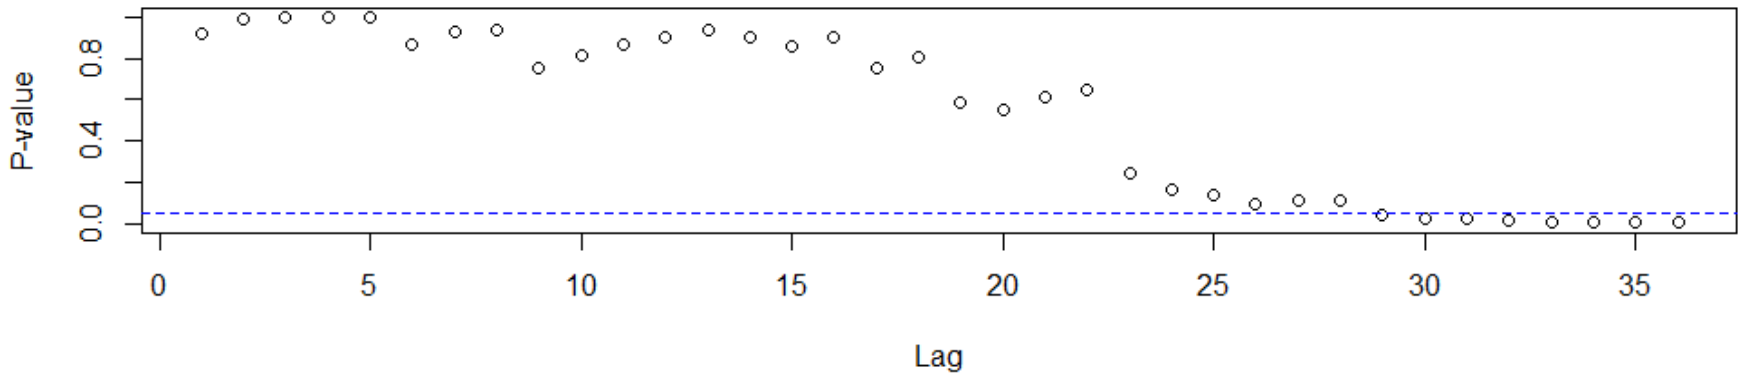

Критерий стационарности KPSS: $p > 0.1$.
Критерий нормальности Шапиро-Уилка: $p = 0.00176$.
Критерий Уилкоксона: $p = 0.3888$.
Критерий гомоскедастичности Бройша-Пагана: $p = 0.0001466$.

auto.arima

Качество на контрольной выборке:

	$RMSE$
ARIMA(3,1,3)$(0,1,1)_{12}$	0.0641
ARIMA(3,0,0)$(2,1,0)_{12}$	0.0661
ARIMA(3,0,1)$(2,1,0)_{12}$	0.0646
ARIMA(3,0,2)$(2,1,0)_{12}$	0.0645
ARIMA(3,0,1)$(1,1,0)_{12}$	0.0679
ARIMA(3,0,1)$(0,1,1)_{12}$	0.0644
ARIMA(3,0,1)$(0,1,2)_{12}$	0.0622
ARIMA(3,0,1)$(1,1,1)_{12}$	0.0630
ARIMA(4,0,3)$(0,1,1)_{12}$	0.0648
ARIMA(3,0,3)$(0,1,1)_{12}$	0.0640
ARIMA(4,0,2)$(0,1,1)_{12}$	0.0648
ARIMA(3,0,2)$(0,1,1)_{12}$	0.0644
ARIMA(2,1,3)$(0,1,1)_{12}$	0.0634
ARIMA(2,1,4)$(0,1,1)_{12}$	0.0632
ARIMA(2,1,5)$(0,1,1)_{12}$	0.0640

Потребление электричества в Турции

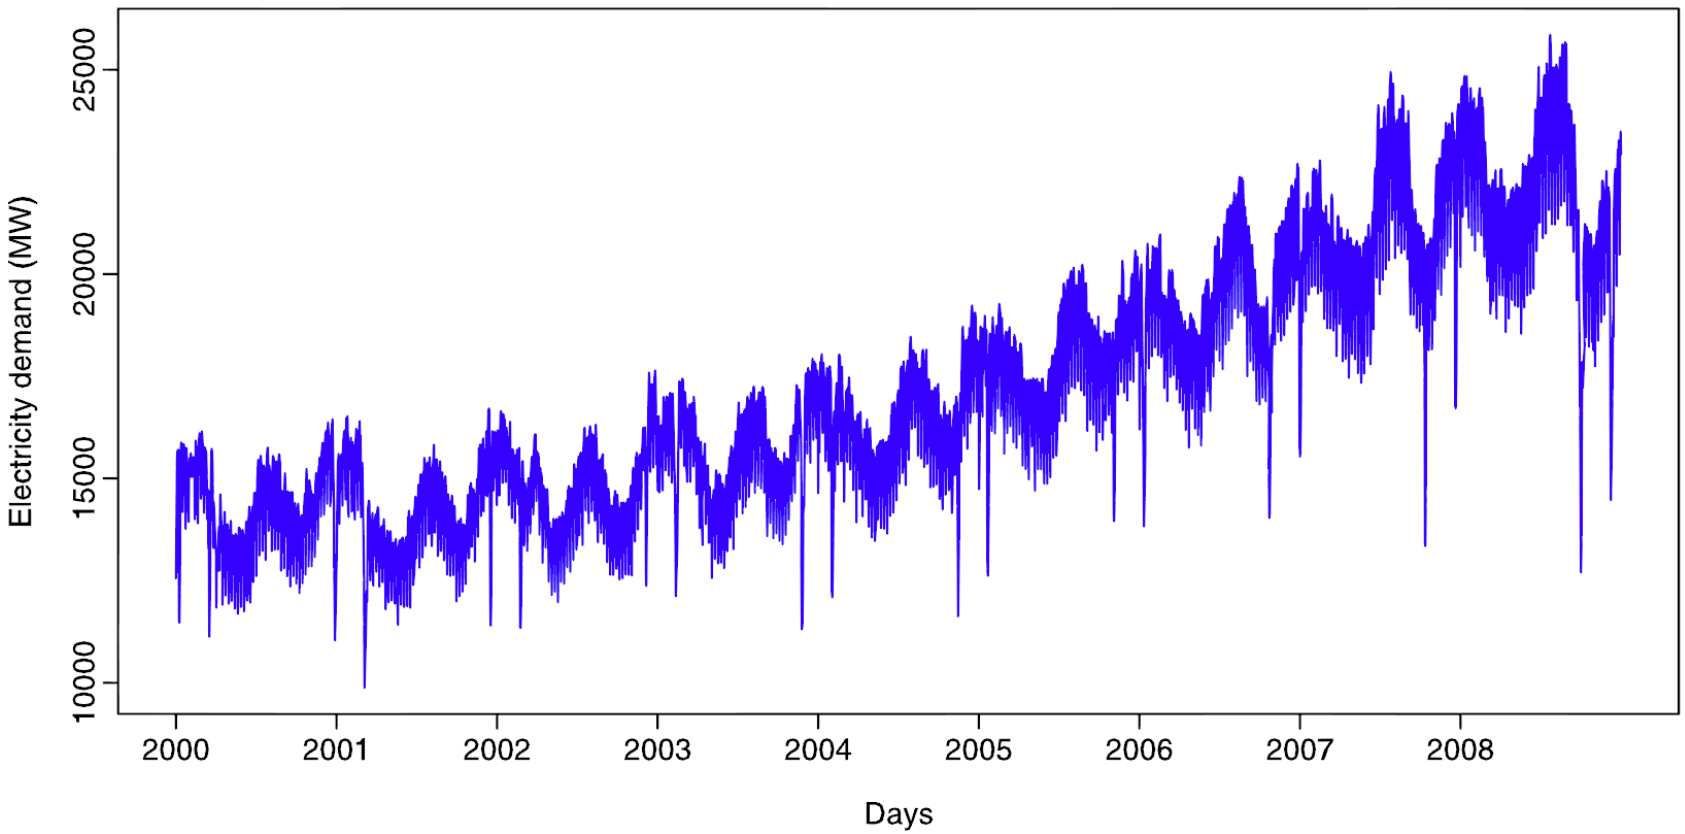

- недельная сезонность;
- годовая сезонность;
- праздники по исламскому календарю (год примерно на 11 дней короче, чем в грегорианском).

regARIMA

Эффекты плавающих праздников, краткосрочных маркетинговых акций и других нерегулярно повторяющихся событий удобно моделировать с помощью regARIMA:

$$\Phi_P\left(B^s\right)\phi\left(B\right)\nabla_s^D\nabla^d z_t = \Theta_Q\left(B^s\right)\theta\left(B\right)\varepsilon_t$$

$$+$$

$$y_t = \sum_{j=1}^{k}\beta_j x_{jt} + z_t$$

$$=$$

$$\Phi_P\left(B^s\right)\phi\left(B\right)\nabla_s^D\nabla^d\left(y_t - \sum_{j=1}^{k}\beta_j x_{jt}\right) = \Theta_Q\left(B^s\right)\theta\left(B\right)\varepsilon_t.$$

Оценка параметров модели

1. Проверить стационарность признаков, если её нет, перейти к разностям. Для лучшей интерпретируемости разностный оператор следует применять и к признакам тоже.
2. Для ряда разностей строится регрессия в предположении, что ошибки описываются моделью начального приближения (как правило, $AR(2)$ или $SARMA(2,0,0) \times (1,0)_s$).
3. Для остатков регрессии $\hat{z}_t$ подбирается подходящая модель $ARMA\,(p_1, q_1)$.
4. Регрессия перестраивается в предположении, что ошибки описываются моделью $ARMA\,(p_1, q_1)$.
5. Анализируются остатки $\hat{\varepsilon}_t$.

Для подзадачи регрессии формальная проверка значимости признаков неприменима, для отбора признаков необходимо сравнивать значения AIC моделей со всеми подмножествами x_j.

Пример: `https://www.otexts.org/fpp/9/1`

Реализации

- US Census Bureau: X-12-ARIMA, X-13-ARIMA-SEATS (`http://www.census.gov/srd/www/x13as/`, доступен через иностранные прокси-серверы);
- Matlab: regARIMA (2013b);
- R: параметр xreg в функциях auto.arima и Arima.

Требования к решению задачи прогнозирования временных рядов

- визуализация данных, анализ распределения признака (оценка необходимости трансформации), оценка наличия выбросов;
- анализ автокорреляционной и частичной автокорреляционной функций;
- настройка модели ARIMA: автоматический подбор модели, проверка её соответствия особенностям ряда, при необходимости — корректировка модели, анализ остатков (нормальность, несмещённость, гомоскедастичность, неавтокоррелированность, стационарность);
- настройка модели экспоненциального сглаживания: автоматический подбор модели, проверка её соответствия особенностям ряда, корректировка, анализ остатков;
- визуальный анализ и формальная проверка наличия структурных изменений в моделях;
- сравнение и выбор лучшей модели по критерию Диболда-Мариано;
- выводы.

Литература

Hyndman R.J., Athanasopoulos G. *Forecasting: principles and practice*. — OTexts, 2013. `https://www.otexts.org/book/fpp`

Hyndman, R.J., Koehler, A.B., Ord, J.K., Snyder, R.D. *Forecasting with Exponential Smoothing: The State Space Approach*. — Berlin: Springer, 2008.