

Санкт-Петербургского государственного политехнического университета. Экономические науки. 2016. № 1 (235). С. 9-29.

2. Бурдакова Г.И., Порваткина Е.В. Развитие инновационного предпринимательства на территории опережающего развития на базе высшего учебного заведения // Инновационная экономика и промышленная политика региона (ЭКОПРОМ-2016): – СПб. : Изд-во Политехн. ун-та, 2016. – 671 с., с. 271-280.

3. Гафуров, И. Р. Инновационные кластеры и социально-экономическое развитие регионов. Анализ методических подходов / И.Р. Гафуров, В.Л. Васильев, Р.Р. Кашбиева. - М.: Анкил, 2016. - 292 с.

4. Кешелава А.В. Введение в цифровую экономику. – ВНИИ Геосистем, 2017. – 28 с.

5. Куприяновский В.П., Синягов С.А., Климов А. А., Петров А. В., Намиот Д.Е. Цифровые цепи поставок и технологии на базе блокчейн в совместной экономике.- International Journal of Open Information Technologies (INJOIT), 2017.

6. Хмелева Г.А., Тюкавкин Н.М., Свиридова С.В., Чертопятов Д.А. Кластерное развитие региона на основе инноваций в условиях санкций (на примере нефтехимического комплекса Самарской области) // Экономические и социальные перемены: факты, тенденции, прогноз. 2017. Т. 10. № 5. С. 83-98.

7. Хмелева Г.А. Направления развития кластерной политики в условиях инновационного развития регионов // Основы экономики, управления и права. 2014. № 3 (15). С. 17-22.

## **ЭКОНОМЕТРИЧЕСКИЙ ПОДХОД К АНАЛИЗУ ВРЕМЕННЫХ РЯДОВ**

**Кудряшов Владислав Владимирович<sup>1</sup>**

Самарский национальный исследовательский университет имени академика  
С.П. Королева, г. Самара

**Аннотация:** В этой статье будет раскрыт способ анализа данных временных рядов с помощью компонентов тренда и сезонности. В статью включено объяснение различных концепций, связанных с моделированием временных рядов, такие как компоненты временных рядов, последовательная корреляция, подбор модели, метрики и т. д. Будет использоваться модель SARIMAX, для моделирования как сезонности, так и тренда в данных. SARIMA (сезонная

---

<sup>1</sup>Студент 4 курса бакалавриата Института экономики и управления Самарского университета. Научный руководитель: Курносова Е.А., кандидат экономических наук, доцент, доцент кафедры экономики инноваций Самарского университета.

ARIMA) способна моделировать сезонность и тренд вместе, в отличие от ARIMA, которая может только моделировать тренд.

**Ключевые слова:** временные ряды, тренд, сезонность, циклы, остатки, автокорреляция, частичная автокорреляция.

#### Определение данных временных рядов

Данные временного ряда представляют собой последовательность точек данных, измеренных за промежутки времени. Другими словами, данные являются функцией времени  $f(t) = y$ .

Точки данных могут измеряться ежечасно, ежедневно, еженедельно, ежемесячно, ежеквартально, ежегодно, а также с меньшими или большими временными масштабами, такими как секунды или десятилетия.

#### Введение в данные

Данные, которые используются в этой статье, представляют собой ежеквартальный уровень безработицы в России в период с 2000 по 2019 год. Данные, использованные в этой статье, не скорректированы с учетом сезонных колебаний, так как будут смоделированы сезонность и тренд.

Если рассмотреть график, то можно заметить тенденцию есть тренд на снижение уровня безработицы, есть крупные всплески связанные с кризисом и так же есть сезонность




Рисунок 1 - График уровня безработицы

Данные временного ряда  $Y$  состоят из комбинации тренда, циклов, сезонности и остатков. Определение терминов приведено ниже:

- Тренд - долгосрочное движение вверх или вниз.
- Цикл - периодическое колебание из-за экономических движений. Это отличается от сезонных колебаний.
- Сезонность - изменение данных, вызванное сезонными воздействиями.

- Остатки - компонент, который остается после того, как другие компоненты были рассчитаны и удалены из данных временных рядов. Распределяется случайным образом, одинаково и независимо.

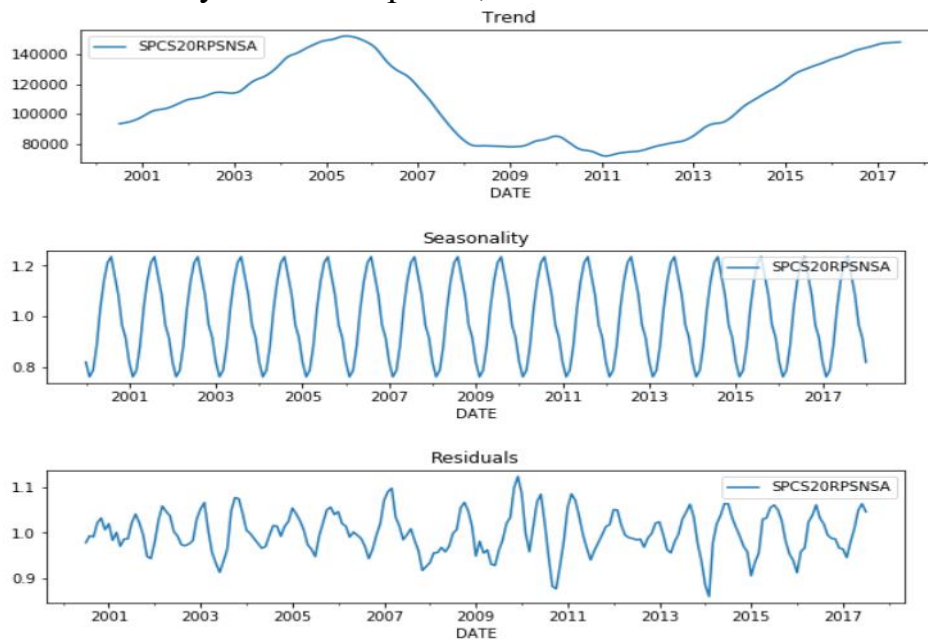


Рисунок 2 - Разложение ряда на компоненты

Стационарность в данных временных рядов.

Когда имеется тенденция или сезонность в данных временного ряда, это называется нестационарным временным рядом.

Стационарность означает, что статистические свойства данных, такие как среднее значение, дисперсия и стандартное отклонение, остаются постоянными во времени.

Почему нужно, чтобы статистические свойства оставались неизменными во времени? Потому что статистические предположения (хорошим примером могут быть предположения OLS) относительно выборочных данных в надлежащее время построения модели, и модель будет способна работать только при этих предположениях. Когда статистические свойства данных изменяются, модель больше не способна представлять истинную природу данных.

Вот почему результаты прогнозов больше не будут действительными. Изменение среднего значения или дисперсии потребует подбора другой модели, и эта модель может быть действительной в течение короткого периода времени, и придется снова отказаться от нее и установить новую модель. Следует сделать данные временного ряда стационарными перед установкой модели. Возможно сделать временной ряд стационарным путем преобразования данных.

Дополненный тест Дики-Фуллера является наиболее популярным для определения стационарности временного ряда, где нулевая гипотеза  $H_0 = \text{data}$  не является стационарной. Результат теста ADF предоставляет статистику теста

и значение  $P$ . Значение  $P > 0,05$  означает, что данные не являются стационарными, в противном случае отвергается нулевая гипотеза и говорится, что данные являются стационарными.

#### Автокорреляция и частичная автокорреляция

График автокорреляции показывает корреляцию данных временных рядов с собственными запаздывающими значениями. Например, автокорреляция при лаге = 1 показывает корреляцию между  $y_t$  и  $y_{t-1}$ . При лаге = 2,  $\text{corr}(y_t, y_{t-2})$ . При лаге = 12  $\text{corr}(y_t, y_{t-12})$ . Каждая точка данных в момент времени  $t$ , имеющая высокую корреляцию с точкой данных в моменты времени  $t-12$ ,  $t-24$  и т. д., обозначает сезонность в этом конкретном примере.




Рисунок 3 - График автокорреляции

Возвращаясь к графику ACF, синяя заштрихованная область на графике автокорреляции показывает уровень значимости. Таким образом, коэффициенты корреляции в заштрихованной области показывают слабую корреляцию при этих лагах, и они не считаются значимыми в анализе. Функция частичной автокорреляции (PACF) дает частичную корреляцию стационарного временного ряда с его собственными запаздывающими значениями.




Рисунок 4 - График частичной автокорреляции

PACF удаляет корреляционный вклад других лагов и дает чистую корреляцию между двумя лагами без влияния других.

ACF и PACF используются, чтобы выбрать правильный порядок для компонентов / функций AR (p) и MA (q) модели ARIMA. Для AR порядка p следует посмотреть на график PACF и значение задержки, которое имеет значительный коэффициент корреляции, прежде чем корреляции станут незначительными. Для MA следует посмотреть на график ACF и сделать то же самое. Нельзя забывать, что нужно получать эти значения только из графиков ACF и PACF стационарных временных рядов, а не из приведенных выше графиков. Графики ACF и PACF, приведенные выше, являются графиками исходных данных, которые являются нестационарными.

#### Преобразование данных

Итак, нужно преобразовать данные, чтобы сделать их стационарными, чтобы можно было начать фазу построения модели. Следует разбить исходные данные на данные обучения и испытаний. Данные обучения будут содержать данные о безработицы с 2000 по 2018 год, а данные испытаний будут содержать данные с 2018 по 2019 год. Нельзя забывать, что не стоит делать случайную выборку, как для данных поперечного сечения. Нужно сохранить временное поведение (зависимость от времени) данных временных рядов.

Данные по индексу безработицы могут быть сформулированы как мультипликативная модель, где  $Y = T * S * R$ . (S) Модели ARIMA являются линейными моделями, такими как линейная регрессия. Невозможно приспособить линейную модель SARIMA к данным, сгенерированным процессом  $Y = T * S * R$ . Нужно сделать Y линейным перед применением линейной модели.

Иногда преобразование ряда само по себе может сделать данные стационарными, но здесь это не так. Дифференцирование - это базовая операция или преобразование данных. Это разница между  $y$  в момент времени  $t$  и  $y$  в момент времени.

Дифференцирование делает данные стационарными, поскольку они удаляют компоненты временных рядов из данных, и остаются изменения между периодами времени. Следует обратить внимание, что разность первого порядка убрала только тренд, а не сезонность. Данные все еще не являются стационарными, поскольку они содержат сезонные эффекты.

Нужно взять разницу 12-го порядка, чтобы убрать сезонность.

Данные сейчас стационарные. Если посмотреть на гистограмму на графике ниже, она выглядит как нормальная кривая колокола. Стационарные данные распределяются случайным образом, и график выглядит как белый шум. Белый шум является лишь примером стационарных данных временных рядов.

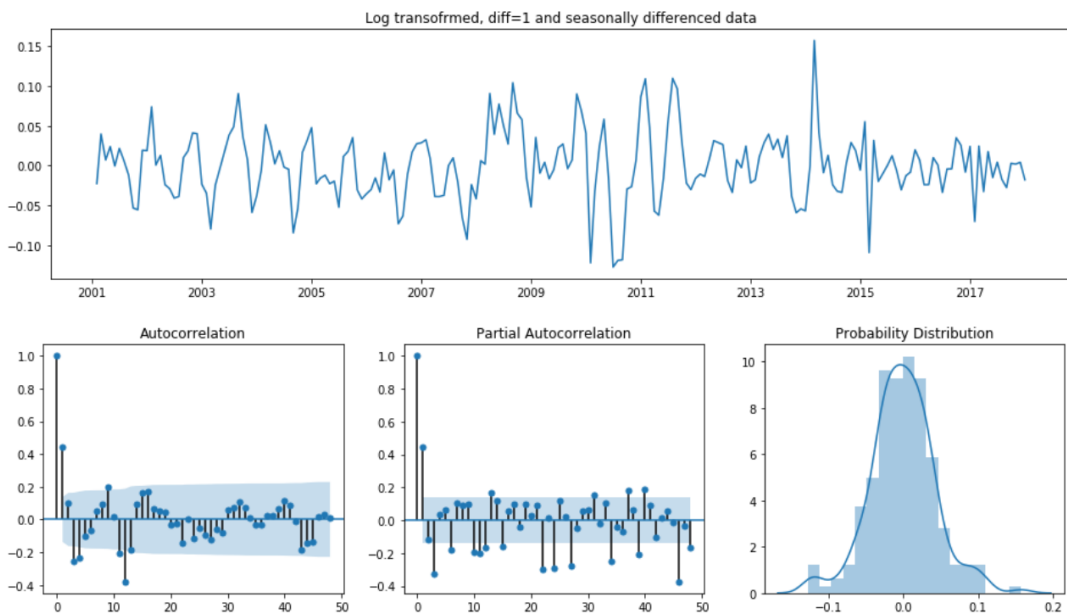


Рисунок 5 - Дифференцированный ряд

### Выбор модели

Поскольку преобразованные данные теперь являются стационарными, можно перейти к фазе подбора модели. Мы остановимся на конкретной модели. SARIMA, Seasonal ARIMA – модель класса ARIMA, который может моделировать сезонную составляющую данных временных рядов.

```
Best model so far: SARIMA(0, 1, 0, 0, 1, 0, 12) AIC:-701.0 BIC:-698.0 HQIC:-700.0 resid:352.481
Best model so far: SARIMA(0, 1, 0, 0, 1, 1, 12) AIC:-775.0 BIC:-769.0 HQIC:-773.0 resid:352.48
Best model so far: SARIMA(0, 1, 1, 0, 1, 1, 12) AIC:-810.0 BIC:-800.0 HQIC:-806.0 resid:352.48
Best model so far: SARIMA(0, 1, 1, 0, 1, 2, 12) AIC:-813.0 BIC:-800.0 HQIC:-808.0 resid:352.48
Best model so far: SARIMA(0, 1, 2, 0, 1, 1, 12) AIC:-846.0 BIC:-833.0 HQIC:-841.0 resid:352.48
```

```
Statespace Model Results
=====
Dep. Variable:          SPCS20RPSNSA      No. Observations:          217
Model:                 SARIMAX(0, 1, 2)x(0, 1, 1, 12)  Log Likelihood             427.105
Date:                  Sun, 21 Apr 2019              AIC                       -846.209
Time:                  23:51:53                     BIC                       -832.937
Sample:                01-01-2000                   HQIC                      -840.840
                    - 01-01-2018

Covariance Type:      opg
=====
              coef      std err          z      P>|z|      [0.025      0.975]
-----
ma.L1          0.5032      0.059         8.581      0.000         0.388         0.618
ma.L2          0.4962      0.044        11.275      0.000         0.410         0.582
ma.S.L12       -0.8698      0.074       -11.747      0.000        -1.015        -0.725
sigma2         0.0008      4.77e-05     17.092      0.000         0.001         0.001
=====
Ljung-Box (Q):          60.57      Jarque-Bera (JB):          376.82
Prob(Q):                0.02      Prob(JB):                  0.00
Heteroskedasticity (H): 2.28      Skew:                      1.29
Prob(H) (two-sided):    0.00      Kurtosis:                  9.14
=====
```

Рисунок 6 - Данные результатов обучения модели

Мы прогнозируем безработицу с 2018–01–01 по 2019–01–01 годы. Для этого будем использовать MAPE - средний абсолютный процент ошибок для оценки

производительности модели. Лучшая модель, которую мы получили, - SARIMA (order = (0,1,2), season\_order = (0,1,1,12)).

Мы делаем прогноз. Ошибка 0.2%. Это означает, что прогнозируемое значение будет смещено от реального значения в среднем на 0.2%. Можно построить прогнозные значения с исходными данными и увидеть результаты.

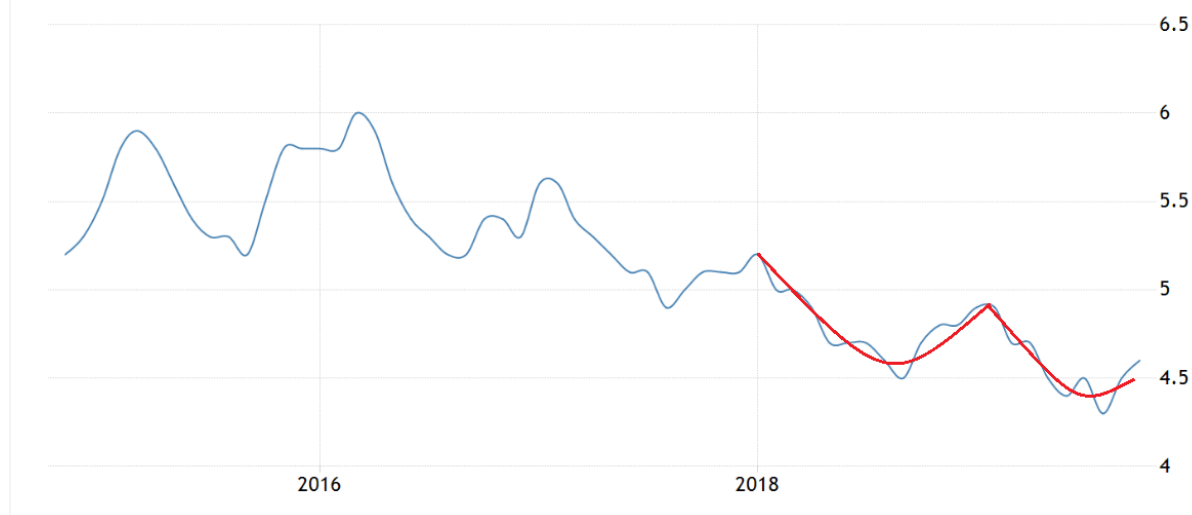


Рисунок 7 - Данные результатов прогноза

## **МОДЕЛЬ «УМНЫЙ ГОРОД» КАК ОСНОВНАЯ ТЕНДЕНЦИЯ ТРАНСФОРМАЦИИ ГОРОДОВ В УСЛОВИЯХ ЦИФРОВИЗАЦИИ**

**Кулик Андрей Алексеевич<sup>1</sup>, Иващук Ангелина Сергеевна<sup>2</sup>**  
Самарский государственный экономический университет, г. Самара

**Аннотация:** Статья посвящена исследованию модели «Умный город», являющейся в настоящее время основной тенденцией трансформации городов в условиях процесса цифровизации. Проведен анализ зарубежного опыта внедрения данной модели. Рассмотрен ведомственный проект «Умный город», внедряемый на территории Российской Федерации, приведены российские достижения и обозначены препятствия, тормозящие его реализацию.

**Ключевые слова:** «умный город», городская среда, цифровизация, урбанизация, «умные решения», рейтинг.

---

<sup>1</sup>Аспирант 2 курса кафедры Региональной экономики и управления Самарского государственного экономического университета. Научный руководитель: Хмелева Г.А. доктор экономических наук, доцент, профессор кафедры «Региональная экономика и управление» Самарского государственного экономического университета.

<sup>2</sup>Студент 4 курса бакалавриата кафедры Региональной экономики и управления Самарского государственного экономического университета. Научный руководитель: Хмелева Г.А. доктор экономических наук, доцент, профессор кафедры «Региональная экономика и управление» Самарского государственного экономического университета.