

Министерство образования и науки Российской Федерации  
ФЕДЕРАЛЬНОЕ ГОСУДАРСТВЕННОЕ БЮДЖЕТНОЕ  
ОБРАЗОВАТЕЛЬНОЕ УЧРЕЖДЕНИЕ ВЫСШЕГО ОБРАЗОВАНИЯ  
«САРАТОВСКИЙ НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ  
ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ ИМЕНИ Н.Г.ЧЕРНЫШЕВСКОГО»

Кафедра теории функций и приближений

**Анализ модели ценообразования на рынке недвижимости**

АВТОРЕФЕРАТ БАКАЛАВРСКОЙ РАБОТЫ

Студента 4 курса 412 группы  
направления 01.03.02 Прикладная математика и информатика

Механико-математический факультет

Зайцева Николая Николаевича

Научный руководитель  
доцент, к.э.н.

\_\_\_\_\_

А.В. Харламов

Заведующий кафедрой  
доцент, д.ф.-м.н.

\_\_\_\_\_

С.П. Сидоров

Саратов 2016

## Введение.

Одной из экономических систем, которая на сегодняшний день занимает важное место в жизни человека, является рынок жилой недвижимости. В последние несколько лет данный рынок получил бурное развитие, что связано с развитием ипотечного кредитования, поиска объектов инвестирования и другими факторами. В рамках тенденций последних лет рост цен на недвижимость сделал ее очень привлекательным объектом инвестиции с целью получения коммерческой выгоды. Квартиры стали приобретаться не только для проживания, но и для вложения в них денежных средств с целью получения дохода.

Таким образом возникла необходимость в изучении и исследовании данного рынка. Существующие методы исследования являются либо упрощенными и недостаточно точными, либо трудоёмкими и сложными (экспертные в рамках индивидуальной оценки недвижимости). Таким образом, актуальным и востребованным становится проведение исследований рынка недвижимости с помощью регрессионного анализа, суть которого заключается в определении основных тенденций ценообразования на рынке. В основе данного метода лежат факторные регрессионные модели, позволяющие оценить влияние на исследуемый объект различных ценообразующих факторов.

Данная методика имеет такие положительные моменты как:

- простота и быстрота расчета;
- способность выявлять и количественно описывать тенденции, которые невозможно оценить на глаз или экспертно на малом количестве наблюдений;
- отсутствие субъективизма со стороны конкретного эксперта рынка жилья.

Полученные результаты можно использовать как в общих аналитических целях, так и в прикладном направлении – для оценки жилой недвижимости.

При проведении теоретических и практических исследований на основе регрессионного анализа зачастую возникают определенные сложности. Большинство их них выражается в недостатках, вызванных как правило ошибками при формулировке модели.

Применение регрессионного анализа для исследования и оценки рынка жилья является актуальным, ввиду особенности изменения порядка определения налогооблагаемой базы при расчете налога на имущество.

Ценообразующим фактором является многообразие условий в которых формируется структура и уровень цены. Целью работы является построение и анализ модели ценообразования на рынках жилья.

К задачам данной работы можно отнести:

- сбор и первичный анализ данных;
- выбор и построение модели;
- выдвижение гипотез и проведение тестов для их проверки;
- анализ полученных данных.

Сама работа содержит в себе две части. В первой описывается классическая нормальная линейная модель множественной регрессии, метод наименьших квадратов, гипотезы и тесты, относящиеся к проверке этих гипотез, а также алгоритмы применяемых тестов. Во второй части эта теория применяется на конкретной задаче рынка недвижимости.

## Основное содержание работы.

Рассмотрим модель множественной регрессии. Обозначим  $i$ -е наблюдение зависимой переменной  $y_i$ , а объясняющие переменные –  $x_{i1}, x_{i2}, \dots, x_{ip}$ . Тогда модель можно представить в виде:

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_p x_{ip} + \varepsilon_i,$$

где  $i=1,2,\dots,n$ ;  $\varepsilon_i$  удовлетворяет предпосылкам регрессионного анализа:

1. В модели возмущение  $\varepsilon_i$  (или зависимая переменная  $y_i$ ) есть величина случайная, а объясняющая переменная  $x_{ij}$  (где  $j=1,2,\dots,p$ ) величина не случайная.

2. Математическое ожидание возмущения  $\varepsilon_i$  равно нулю:

$$M(\varepsilon_i) = 0.$$

3. Дисперсия возмущения  $\varepsilon_i$  постоянна для любого  $i$ :

$$D(\varepsilon_i) = \sigma^2.$$

Модель в которой зависимая переменная  $y_i$ , возмущения  $\varepsilon_i$ , и объясняющие переменные  $x_{i1}, x_{i2}, \dots, x_{ip}$  удовлетворяют приведенным предпосылкам регрессионного анализа и, кроме того, предпосылке о невырожденности матрицы (независимости столбцов) значений объясняющих переменных, называется *классической нормальной линейной моделью множественной регрессии*.

Введем обозначения:  $Y$  - матрица-столбец, или вектор, значений зависимой переменной размера  $n$ ;  $X$  - матрица значений объясняющих переменных, или матрица плана размера  $n \times (p+1)$ ;  $\beta$  - матрица-столбец, или вектор, параметров размера  $(p+1)$ ;  $\varepsilon$  - матрица-столбец, или вектор, возмущений размера  $n$ .

Тогда в матричной форме модель примет вид:

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

Оценкой этой модели по выборке является уравнение

$$\hat{Y} = Xb + e.$$

Для оценки вектора неизвестных параметров  $\beta$  применяется метод наименьших квадратов. Так как произведение транспонированной матрицы на саму матрицу есть:

$$e'e = \sum_{i=1}^n e_i^2,$$

условие минимизации остаточной суммы квадратов запишется в виде:

$$S = \sum_{i=1}^n (\hat{y}_{x_i} - y_i)^2 = e'e = \sum_{i=1}^n e_i^2 = (Y - Xb)'(Y - Xb) \rightarrow \min.$$

На основании необходимого условия экстремума функции нескольких переменных  $S(b_1, b_2, \dots, b_n)$ , представляющей необходимо приравнять нулю частные производные по этим переменным или в матричной форме – вектор частных производных

$$\frac{\partial S}{\partial b} = \left( \frac{\partial S}{\partial b_0} \frac{\partial S}{\partial b_1} \dots \frac{\partial S}{\partial b_p} \right).$$

Для вектора частных производных получается система нормальных уравнений в матричной форме для определения вектора  $b$ :

$$X'Xb = X'Y$$

Для решения матричного уравнения относительно вектора оценок параметров  $b$  необходимо ввести предпосылку:

Векторы значений объясняющих переменных, или столбцы матрицы плана  $X$ , должны быть линейно независимыми, т.е. ранг матрицы  $X$  – максимальный ( $r(X) = p+1$ ).

*Теорема Гаусса-Маркова:*

1.  $Y_t = a + bX_t + \varepsilon_t, \quad t = 1, \dots, n;$
2.  $X_t$  – детерминированная величина;
3.  $E\varepsilon_t = 0, \quad E(\varepsilon_t^2) = V(\varepsilon_t) = \sigma^2;$
4.  $E(\varepsilon_t \varepsilon_s) = 0, \quad \text{при } t \neq s.$

Оценки, полученные по методу наименьших квадратов, имеют наименьшую дисперсию в классе всех линейных несмещенных оценок.

Рассмотрим оценку значимости коэффициентов регрессии  $b_j$  и построение доверительного интервала для параметров регрессионной модели  $\beta_j$  ( $j=1,2,\dots,p$ ).

Значимость коэффициента регрессии  $b_j$  можно проверить, если учесть, что статистика  $(b_j - \beta_j)/s_{b_j}$  имеет t-распределение Стьюдента с  $k=n-p-1$  степенями свободы. Поэтому  $b_j$  значимо отличается от нуля на уровне значимости  $\alpha$ , если  $|t| = \frac{|b_j|}{s_{b_j}} > t_{1-\alpha;n-p-1}$ , где  $t_{1-\alpha;n-p-1}$  – табличное значение t-критерия Стьюдента, определенное на уровне значимости  $\alpha$  при числе степеней свободы  $k=n-p-1$ .

В общей постановке гипотеза о равенстве параметра  $\beta_j$  заданному числу  $\beta_{j0}$ , отвергается если

$$|t| = \frac{|b_j - \beta_{j0}|}{s_{b_j}} > t_{1-\alpha;n-p-1}.$$

Поэтому доверительный интервал для параметра  $\beta_j$  есть

$$b_j - t_{1-\alpha;n-p-1}s_{b_j} \leq \beta_j \leq b_j + t_{1-\alpha;n-p-1}s_{b_j}.$$

В модели множественной регрессии общая вариация  $Q$  – сумма квадратов отклонений зависимой переменной от средней может быть разложена на две составляющие:

$$Q = Q_R + Q_e.$$

Уравнение множественной регрессии значимо, если

$$F = \frac{Q_R(n-p-1)}{Q_e p} > F_{\alpha;p;n-p-1},$$

где  $F_{\alpha;p;n-p-1}$  – табличное значение F-критерия Фишера-Снедекора.

Коэффициент детерминации  $R^2$  одна из наиболее эффективных оценок регрессионной модели, мера качества уравнения регрессии. Определяется по формулам:

$$R^2 = \frac{Q_R}{Q} = \frac{b'X'Y - n\bar{y}^2}{Y'Y - n\bar{y}^2},$$

$$R^2 = 1 - \frac{Q_e}{Q}.$$

$R^2$  характеризует долю вариации зависимой переменной, обусловленной регрессией или изменчивостью объясняющих переменных.

Перейдем к поиску доверительного интервала и проверке гипотез.

Проверим гипотезу  $H_0: \beta_i = \beta_{i0}$ , с статистическими результатами: вектор оценок  $\hat{\beta}_{OLS}$  имеет нормальное распределение со средним  $\beta$  и матрицей ковариаций  $V(\beta_{OLS,i}) = \sigma^2 (X'X)^{-1}$ , т.е.  $\beta_{OLS,i} - \beta_i \sim N(0, \sigma_{\beta_i}^2)$ , где  $\sigma_{\beta_i}^2 = \sigma^2 q^{ii}; q^{ii}$  -  $i$ -й диагональный элемент матрицы. В качестве оценки дисперсии берется  $s_{\beta_i}^2 = \sigma_{\beta_i}^2 = \sigma^2 q^{ii} = s^2 q^{ii}$ . Случайная величина  $(n-k) \frac{s^2}{\sigma^2}$  распределена по закону  $\chi^2(n-k)$ . Оценки  $\beta_{OLS}$  и  $s^2$  независимы. Получаем статистику

$$t = \frac{\beta_{OLS,i} - \beta_i}{s_{\beta_i}} = \frac{(\beta_{OLS,i} - \beta_i) / \sigma_{\beta_i}}{s_{\beta_i} / \sigma_{\beta_i}} \sim t(n-k),$$

из которой интервал

$$\left[ \beta_{OLS,i} - t_c s_{\beta_i}; \beta_{OLS,i} + t_c s_{\beta_i} \right]$$

является  $100(1-\alpha)\%$ -ным доверительным интервалом для истинного значения коэффициента  $\beta_i$ , где  $t_c = t_{\alpha/2}(n-k) - 100(\alpha/2)\%$ -ная точка распределения Стьюдента.

Пусть  $H_0: \beta_2 = \beta_3 = \dots = \beta_k = 0$ . Предположим, что в число регрессоров включена константа:  $y_t = \beta_1 + \beta_2 x_{t2} + \dots + \beta_k x_{tk} + \varepsilon_t$ . Нулевая гипотеза состоит в том, что коэффициенты при всех регрессорах равны нулю.

Рассмотрим статистику

$$F = \frac{R^2}{1-R^2} \frac{n-k}{k-1} = \frac{RSS}{ESS} \frac{n-k}{k-1} = \frac{\sum (\hat{y}_t - \bar{y})^2 / (k-1)}{\sum e_t^2 / (n-k)} = \frac{\hat{y}'_* \hat{y}_*}{e'e} \frac{1}{n-k}.$$

Из Теоремы Гаусса-Маркова и оценок дисперсии возмущений,  $\hat{\beta}_{OLS}$  и  $e$  независимы, поэтому статистика  $F$  имеет распределение Фишера

$$F = \frac{R^2}{1-R^2} \frac{n-k}{k-1} = \frac{RSS}{ESS} \frac{n-k}{k-1} = \frac{(\hat{y}_t - \bar{y})^2 / (k-1)}{e_t^2 / (n-k)} = \frac{\hat{y}'_* \hat{y}_* / (k-1)}{e'e / (n-k)} \sim F(k-1, n-k),$$

и её можно использовать для проверки гипотезы  $H_0: \beta_2 = \beta_3 = \dots = \beta_k = 0$ . Гипотеза отвергается на 5%-ном уровне значимости, если  $F > F_c$ , где  $F_c = F_{0.05}(k-1, n-k)$  - 5%-ная точка распределения Фишера.

Выбор регрессоров называется *спецификацией модели*. Поэтому возникает естественный вопрос соотношения между МНК-оценками параметров в истинной и выбранной моделях. Рассмотрим две ситуации: в оцениваемой модели отсутствует часть независимых переменных, имеющих в истинной модели (исключение существенных переменных); в оцениваемой модели присутствуют независимые переменные, которых нет в истинной модели (включение несущественных переменных). Рассмотрим два основных случая.

*Случай 1. Исключены существенные переменные.*

Процесс, порождающий данные:  $y = X\beta + Z\gamma + \varepsilon$ .

Модель:  $y = X\beta + \varepsilon$ .

*Случай 2. Включены несущественные переменные.*

Процесс, порождающий данные:  $y = X\beta + \varepsilon$ .

Модель:  $y = X\beta + Z\gamma + \varepsilon$ .

где  $y - n \times 1$  вектор наблюдений зависимой переменной;  $X - n \times k$  и  $Z - n \times l$  матрицы;  $\beta - k \times 1$  и  $\gamma - l \times 1$  векторы коэффициентов.

Рассмотрим постановку задачи, когда нам неизвестен процесс, порождающий данные. Таким образом, мы сравниваем две модели:

I.  $y = X\beta + Z\gamma + \varepsilon$  (модель без ограничений),

II.  $y = X\beta + \varepsilon$  (модель с ограничениями),

будем использовать индексы  $u$  и  $r$  для моделей без ограничений и с ограничениями соответственно.

Для выбора одной из этих моделей существует два способа.

*Способ 1*

$$R^2 = 1 - \frac{e'e}{y'Ay}; \quad A = I_n - \frac{1}{n}ii'; \quad R_{adj}^2 = 1 - \frac{e'e/(n-k)}{y'Ay/(n-1)}.$$

Для модели с ограничением и без ограничения получаем соответственно

$$R_{u,adj}^2 = 1 - \frac{e'_u e_u / (n-k-1)}{y'Ay / (n-1)}; \quad R_{r,adj}^2 = 1 - \frac{e'_r e_r / (n-k)}{y'Ay / (n-1)};$$

$$R_{r,adj}^2 - R_{u,adj}^2 = \frac{e'_u e_u / (n-k-1) - e'_r e_r / (n-k)}{y'Ay / (n-1)}.$$

Гипотезу  $H_0: \gamma = 0$  проверяем с помощью  $F$ -статистики (или  $t$ -статистики):

$$F = \frac{(e'_r e_r - e'_u e_u) / 1}{e'_u e_u / (n-k-1)} \sim F(1, n-k-1) \sim t^2(n-k-1).$$

Следовательно,

$$R_{r,adj}^2 - R_{u,adj}^2 = \frac{e'_u e_u / (n-k-1) - e'_r e_r / (n-k)}{y'Ay / (n-1)} \cdot \frac{1-t^2}{n-k}.$$

Таким образом, если  $|t| > 1$ , то  $R_{r,adj}^2 < R_{u,adj}^2$ , и наоборот. Если верить, что скорректированный коэффициент детерминации  $R_{adj}^2$  является правильным критерием, то мы должны выбрать модель без ограничения тогда, когда  $|t| > 1$ .

*Способ 3* (основан на наименьшем среднеквадратичном отклонении MSE).

Сравним модели I и II по критерию  $MSE(\hat{\beta})' = E\left(\left(\hat{\beta} - \beta\right)' \left(\hat{\beta} - \beta\right)\right)$ .

Обозначим  $M = I - X(X'X)^{-1}X'$  и также введем обозначения

$$q = \frac{\sigma}{\sqrt{z'Mz}}(X'X)^{-1}X'z; \quad \theta = \frac{\gamma}{\sigma/\sqrt{z'Mz}}.$$

Предположим, что вектор ошибок имеет стандартное многомерное нормальное распределение, тогда следует, что

$$\hat{\beta}_r \sim N\left(\beta + \theta q, \sigma^2(X'X)^{-1}\right); \quad \hat{\beta}_u \sim N\left(\beta, \sigma^2(X'X)^{-1} + qq'\right).$$

Отсюда по свойствам нормального распределения получаем

$$MSE(\hat{\beta}_r) - MSE(\hat{\beta}_u) = (\theta^2 - 1)q'q.$$

Условие  $|\theta| > 1$  важно, но тут  $\theta$  - «теоретическое  $t$ -отношение», а не полученное из наблюдений.

Необходимо знать «что лучше  $\hat{\beta}_r$  или  $\hat{\beta}_u$ » и правильно будет задать вопрос «верна ли гипотеза  $H_0: |\theta| > 1$ ?», так как это условие различает, какое из чисел больше:  $MSE(\hat{\beta}_r)$  или  $MSE(\hat{\beta}_u)$ .

Применение обобщенного метода наименьших квадратов при наличии гетероскедастичности сводится к минимизации суммы взвешенных квадратов отклонений. использование доступного обобщенного метода наименьших квадратов в общем случае требует оценивания  $n$  параметров по  $n$  наблюдениям, что не позволяет получать состоятельные оценки. В некоторых ситуациях (ошибка пропорциональна одной из независимых переменных, дисперсии ошибок принимают два значения) можно применять доступный обобщенный метод наименьших квадратов и получать состоятельные оценки коэффициентов регрессии.

## Заключение.

В данной работе рассматривается такой социально-экономический вопрос как ценообразующие факторы рынка недвижимости. Данный рынок имеет постоянный интерес со стороны общества. Вопрос сравнительных преимуществ жилья приходилось, приходится и придется решать многим, тем кто меняет свои жилищные условия и тем, кто инвестирует свои денежные средства.

Интерес анализа данного рода задач объясним тем, что к ним можно подойти с математической точки зрения, применяя как в данной работе регрессионный анализ и соответствующие тесты. Такой подход в данном вопросе помогает систематизировать информацию и упростить анализ и решение такого рода задач, путем автоматизации по средствам вычислительной техники и различного рода программного обеспечения.

Применяемый метод наименьших квадратов показывает свою адекватность при должном подборе оцениваемой модели. В ходе работы выяснилось, что логарифмическая форма модели и даваемые ей оценки наиболее эффективны. В случае использования линейной формы модели возникает необходимость борьбы с гетероскедастичностью в выборке, что является не тривиальной задачей.

Проделанные тесты на гетероскедастичность отвечают на вопрос о неоднородности наблюдений. По этому параметру логарифмическая форма модели наиболее приемлема для использования в исследованиях.

Про тест Чоу можно сказать то, что данная процедура проверяет стабильность параметров регрессионной модели. По факту тест проверяет неоднородность выборки в контексте регрессионной модели. Проведенный в работе тест указал на возможность сравнения двух рынков недвижимости одной общей моделью. Но стоит заметить, что такое возможно для теоретических исследований и может не работать на практике.

Анализируя модели и проделанные тесты ценообразующими факторами на рынке недвижимости для 1-комнатных квартир, можно указать такие параметры как: площадь квартиры, площадь кухни и жилой комнаты для вторичного рынка недвижимости, основной материал из которого построен дом, расстояние до центра города. Стоит отметить, что такие параметры являются достаточно общими и могут добавляться различными параметрами при дополнительном и более детальном рассмотрении рынка.