

**ИССЛЕДОВАТЕЛЬСКАЯ СТАТЬЯ**<https://doi.org/10.17059/ekon.reg.2022-2-x>

УДК 339.13.017

**Л. Н. Ясницкий<sup>a)</sup>, В. Л. Ясницкий<sup>b)</sup>, А. О. Алексеев<sup>a)</sup>**<sup>a)</sup> НИУ «Высшая школа экономики» в Перми; Пермский государственный национальный исследовательский университет, г. Пермь, Российская Федерация<sup>b,</sup><sup>b)</sup> Пермский национальный исследовательский политехнический университет, г. Пермь, Российская Федерация<sup>a)</sup> <https://orcid.org/0000-0002-8212-3826>, e-mail: yasn@psu.ru<sup>b)</sup> <https://orcid.org/0000-0002-8881-533X><sup>b)</sup> <https://orcid.org/0000-0001-5033-6694>

## **Моделирование рынков жилой недвижимости крупнейших городов России<sup>1</sup>**

*Существующие математические модели массовой оценки и прогнозирования рыночной стоимости жилых объектов обладают рядом недостатков: разработанные для какого-либо одного региона, они не годятся для других регионов. Все они быстро устаревают и требуют постоянной актуализации, поскольку не учитывают постоянно меняющуюся экономическую обстановку. Они не пригодны для оптимизации строительного бизнеса. Целью исследования является создание системы оценки недвижимости городов России, применимой к любым ее регионам, причем независимо от постоянно меняющейся экономической ситуации. Эта цель была достигнута благодаря тому, что в качестве входных параметров нейронной сети помимо строительно-эксплуатационных факторов были учтены географические параметры, фактор времени, а также ряд параметров, характеризующих экономическую ситуацию в конкретных регионах, в России и в мире. Статистические данные о рынках недвижимости РФ, необходимые для обучения нейронной сети, были собраны за длительный период с 2006 г. по 2020 г., что обусловило ее динамические свойства. В качестве примера применения системы были проведены виртуальные компьютерные эксперименты, которые, например, показали, что в Москве самую высокую удельную стоимость квадратного метра имеют однокомнатные квартиры минимальных размеров – 16 м<sup>2</sup>. Максимальная стоимость двухкомнатных квартир достигается при их площади 90 м<sup>2</sup>, трехкомнатных – 100 м<sup>2</sup>, четырехкомнатных – 110 м<sup>2</sup>, пятикомнатных – 120 м<sup>2</sup>. Для условий Екатеринбурга среди двухкомнатных квартир наибольшую стоимость квадратного метра имеют квартиры общей площадью 30 м<sup>2</sup>, трехкомнатных – 110 м<sup>2</sup>, четырехкомнатных – 130 м<sup>2</sup>, пятикомнатных – 150 м<sup>2</sup>. Таким образом, система может быть использована для оптимизации строительного бизнеса. Она может быть полезна государственным структурам, занимающимся вопросами управления рынком городской недвижимости, вопросами имущественного налогообложения, вопросами повышения эффективности жилищного рынка.*

**Ключевые слова:** массовая оценка, рыночная стоимость, рынок недвижимости, жилая недвижимость, налогообложение, прогнозирование, строительный бизнес, нейронная сеть, сценарное прогнозирование, ценоевые зоны.

### **Благодарность**

*Исследования и публикация статьи финансировались Российской фондом фундаментальных исследований: Грант № 19-010-00307 «Разработка интеллектуальной самоадаптируемой системы массовой оценки и сценарного прогнозирования рыночной стоимости жилой недвижимости регионов РФ».*

*Авторы выражают глубокую признательность авторитетным специалистам в области оценки имущества: Геннадию Моисеевичу Стернику, Сергею Геннадьевичу Стернику и Евгению Иосифовичу Нейману за полезные консультации и поддержку.*

*Авторы благодарны Илье Наилевичу Нуруллину за разработку удобного пользовательского интерфейса.*

**Для цитирования:** Ясницкий Л. Н., Ясницкий В. Л., Алексеев А. О. Моделирование рынков жилой недвижимости крупнейших городов России // Экономика региона. 2022. Т. 18, вып. 2. С. xx-xx. <https://doi.org/10.17059/ekon.reg.2022-2-x>.

<sup>1</sup> © Ясницкий Л. Н., Ясницкий В. Л., Алексеев А. О. Текст. 2022.

**Leonid N. Yasnitsky<sup>a)</sup>, Vitaliy L. Yasnitsky<sup>b)</sup>, Aleksandr O. Alekseev<sup>c)</sup>**

<sup>a)</sup> National Research University "Higher School of Economics" in Perm, Perm, Russian Federation

<sup>a)</sup> Perm State University, Perm, Russian Federation

<sup>b, c)</sup> Perm National Research Polytechnic University, Perm, Russian Federation

<sup>a)</sup> <https://orcid.org/0000-0002-8212-3826>, e-mail: yasn@psu.ru

<sup>b)</sup> <https://orcid.org/0000-0002-8881-533X>

<sup>c)</sup> <https://orcid.org/0000-0001-5033-6694>

## Simulation of Residential Real Estate Markets in the Largest Russian Cities

The existing mass appraisal models and mathematical tools for predicting the market value of residential property have a number of disadvantages, as they are developed for individual regions. Without considering the constantly changing economic environment, these models quickly become outdated and require constant updating. Thus, they are not suitable for construction business optimisation. The study aims to create a universally applicable real estate appraisal system for Russian cities, regardless of the constantly changing economic situation. This goal was achieved through the creation of a neural network, whose input parameters include construction and operational data, geographical factors, time effect, as well as a number of indicators characterising the economic situation in specific regions, Russia and the world. In order to examine the dynamics of real estate markets in the Russian Federation, statistical data for neural network training were collected over a long period from 2006 to 2020. Virtual computer experiments were performed for testing the developed system. They showed that minimum size one-room apartments of 16 square meters have the highest unit cost per square meter in Moscow. Two-room apartments with an area of 90 square meters have the maximum price, as well as 100 sq. m. three-room, 110 sq. m. four-room and 120 sq. m. five-room apartments. In Ekaterinburg, two-room apartments with a total area of 30 square meters have the highest cost per square meter; the same applies for 110 sq. m. three-room, 130 sq. m. four-room and 150 sq. m. five-room apartment. Thus, the proposed system can be used to optimise the construction business. It can be also be useful for government institutions concerned with urban real estate market management, property taxation, and housing market improvement.

**Keywords:** mass appraisal, market value, real estate market, residential property, taxation, forecasting, construction business, neural network, scenario forecasting, price zones

### Acknowledgments

The article has been prepared with the support of the Russian Foundation for Basic Research, the grant No. 19-010-00307 "Development of intellectual self-adaptive system of mass valuation and scenario forecasting of the market value of residential real estate in the regions of the Russian Federation".

The authors express their deep gratitude to the authoritative experts in the field of property valuation: Gennady Moiseevich Sternik, Sergey Gennadievich Sternik and Evgeny Iosifovich Neiman for their support and useful advice.

The authors are grateful to Ilya Nailevich Nurullin for developing a convenient user interface.

**For citation:** Yasnitsky, L. N., Yasnitsky, V. L. & Alekseev, A. O. (2022). Simulation of Residential Real Estate Markets in the Largest Russian Cities. *Ekonomika regiona [Economy of regions]*, 18(2), xx-xx, <https://doi.org/10.17059/ekon.reg.2022-1-x>.

### Введение

Результаты разработки математических моделей рынков недвижимости отражены в исследованиях многих зарубежных и отечественных ученых. Актуальность данных исследований обусловлена использованием систем поддержки принятия решений в задачах администрирования имущественного налогообложения (Davis, 2012; Manganelli, 2014; Oshodi, 2019), планирования территориальных преобразований (Manganelli, 2014), планирования строительства жилых объектов (Ćetković, 2018), что необходимо для инвесторов, финансовых институтов, покупателей, так как информа-

ция о рыночной стоимости городской недвижимости является аналитической поддержкой для принятия решений (Oshodi, 2019) и обеспечивает смягчение последствий отрицательных рыночных явлений.

До 1990 г. для оценки объектов недвижимости применялись пять основных методов: сравнительный метод (*comparation method*), затратный метод (*costmethod*), остаточный метод (*development method*), доходный метод (*accounts method*) и метод капитализации (*capitalization / incomemethod*) (Xiao, 2017).

Начиная с 1990-х гг. и по настоящее время наблюдается повышенный интерес к приме-

нению методов искусственного интеллекта. Наряду с искусственными нейронными сетями обсуждаются возможности применения методов нечеткой логики. Однако последние пока не нашли широкого распространения. В качестве причин некоторые авторы (Родина, 2009; Дьяков, 2016) отмечают субъективизм нечетких логических моделей, являющийся следствием неопределенности выбора функций принадлежности и формирования правил нечеткого выбора. Поэтому, там, где это возможно, рекомендуется пользоваться методами, основанными на количественных статистических данных, которые объективны по своей природе. И действительно, в литературе имеются примеры (Malaman, 2017), где на конкретных примерах показано, что в городских условиях, когда объекты недвижимости могут быть охарактеризованы четкими количественными параметрами, модели, полученные путем применения математического аппарата нечеткой логики, имеют более высокую погрешность, чем обычные регрессионные модели.

Есть мнение (Renigier-Biżozor, 2019), что метод нечеткой логики имеет смысл применять для оценки недвижимости в условиях сельской местности, для которой обычно не имеется достаточного количества количественных статистических данных. Для оценки же городской недвижимости в настоящее время наиболее широкое распространение получили искусственные нейронные сети.

Первой работой на эту тему, по-видимому, можно назвать статью (Borst, 1991), опубликованную в 1991 г. R.A. Borst рассматривал нейронную сеть как черный ящик, на вход которого подавал строительно-эксплуатационные параметры объектов недвижимости (площадь, тип дома, этаж и т. д.), а на выходе получал рыночную стоимость объектов. Обучение нейронной сети на статистической информации сделок продажи недвижимости на данных Нью-Йорка показало, что модель способна прогнозировать цену объектов недвижимости с точностью до 90 %.

В 1991 году D.P. Tay и D.K. Ho в статье (Tay, Ho, 1992) опубликовали результаты применения аналогичного подхода для оценки недвижимости Тайваня, а A. Evans в (Evans, 1991) — Великобритании.

В 1992 г. A.Q. Do и G. Grudnitski (Do, Grudnitski, 1992) применили нейронную сеть для оценки недвижимости Сан-Диего (США).

Начиная с 1992 г. и по настоящее время в зарубежной литературе появляется множество публикаций (Borst, 1995; Guan, 2008; Manganelli,

2014; Abidoye, 2017; Oshodi, 2019; Бочки, 2020), посвященных применению нейронных сетей для оценки стоимости жилых объектов. Во многих работах отмечается преимущества использования математического аппарата нейронных сетей по сравнению регрессионным анализом и другими методами оценки недвижимости. В обзорной работе (Abidoye, 2017), опубликованной в 2017 г., дан анализ 80 публикаций, посвященных применению нейронных сетей для оценки недвижимости. В качестве входных параметров нейросетевых моделей исследователями были использованы строительно-эксплуатационные параметры с небольшими модификациями. Причем каждая из нейронных сетей обучалась на данных только одного какого-либо региона. Вопросами применения метода нейросетевого моделирования для выявления и исследования закономерностей региональных рынков недвижимости, тем более, сравнения их между собой, указанные авторы не занимались. В заключении обзорной работы (Abidoye, 2017) было отмечено, что четверть всех 80 проанализированных статей была написана в США, остальные исследования были проведены учеными преимущественно развитых стран.

В России первая нейросетевая система массовой оценки объектов недвижимости была создана в 2008 г. Л.Н. Ясницким с соавторами (Ясницкий, 2008). Система показала погрешность в прогнозировании стоимости квартир 16,4 %. В отличие от своих предшественников, автор применил разработанную модель для выявления закономерностей моделируемого жилищного рынка, выявил зависимости стоимости квартиры от удаленности дома от центра города, типа дома и его технического состояния, исследовал на основании этих зависимостей эффективность инвестиционных вложений и их влияние на рыночную стоимость недвижимости, представил практические рекомендации.

В 2009 г. К.К. Борусяк, И.В. Мунерман и С.С. Чижов (Борусяк, Мунерман, Чижов, 2009) разработали для Департамента имущества г. Москвы нейронную сеть, предназначенную для оценки нежилой недвижимости. Средняя относительная погрешность нейросетевой оценки имущества составила 20,0 %. В 2011 г. эта методика получила дальнейшее развитие и применение в диссертации И.В. Мунермана (Мунерман, 2011).

Подводя итог выполненному аналитическому обзору, можно обратить внимание на недостатки существующих моделей:

1. Все существующие модели быстро устаревают и требуют систематической актуализации, поскольку не учитывают меняющиеся региональные и внешнеэкономические условия. Такие модели будем называть статическими. Отмеченный недостаток статических моделей наиболее характерен при моделировании жилищных рынков развивающихся стран, включая Россию. Жилищные рынки развивающихся стран довольно существенно зависят от изменяющихся во времени цен на энергоресурсы, валютные курсы, фондовые индексы и др.

2. Разработанные для какого-либо одного региона, статические модели непригодны для применения в условиях других регионов, так как не учитывают их мезоэкономические параметры.

3. Статические модели не годятся для выполнения сравнительного анализа рынков недвижимости различных регионов и не позволяют выявлять их системные закономерности.

Вместе с тем, можно заметить, что имеются модели, которые можно назвать динамическими, так как они учитывают некоторые макроэкономические критерии и предназначены для исследования рынка недвижимости в целом (Abidoye, 2019; Abidoye, 2017; Četković, 2018; Davis, 2012; Анимица, 2010; Стерник, 2009; Молчанова, 2015). Но указанные динамические модели плохо подходят для массовой оценки недвижимости, поскольку не учитывают индивидуальные (статических) характеристик жилых объектов.

В связи с этим авторами настоящей работы была опубликована статья (Yasnitsky, 2016), в которой предложены методики создания нейросетевых комплексных экономико-математических моделей, обладающих общими свойствами описанных выше статических и динамических моделей. Предложенные авторские модели учитывают как строительно-эксплуатационные характеристики объектов недвижимости, так и экономические параметры. Благодаря этому модели приобрели свойство самоадаптируемости ко времени, то есть сохраняют свои прогностические способности независимо от меняющейся со временем внешней экономической среды.

Таким образом, был устранен первый недостаток.

Однако по-прежнему остаются неустранимыми второй и третий недостатки, то есть разработанные для какого-либо одного региона, комплексные нейросетевые модели не могут быть применены для других регионов и, как следствие, с помощью таких моде-

лей нельзя выполнять сравнительный анализ рынков недвижимости различных регионов, нельзя выявлять специфические особенности закономерностей рынков недвижимости регионов.

Между тем, как отмечают некоторые современные исследователи (например (Yasnitsky, 2020)) при планировании развития городов, а также при стратегическом планировании деятельности строительных организаций, при разработке мер государственного регулирования региональных рынков недвижимости, политики ипотечного кредитования, политики налогообложения, необходим индивидуализированный подход, учитывающий особенности и закономерности поведения рынков недвижимости отдельных регионов.

В связи с этим цель настоящего исследования состоит в дальнейшем развитии результатов предыдущих разработок и создании математических моделей, обладающих свойством самоадаптирования не только ко времени, но и к пространству. Другими словами, цель исследования состоит в том, чтобы научиться создавать самоадаптирующиеся к меняющейся экономической ситуации интеллектуальные системы сценарного прогнозирования рынков жилой недвижимости, пригодные для применения одновременно ко многим городам, позволяющие моделировать и выявлять особенности, выполнять сравнительный анализ и изучать закономерности поведения локальных рынков недвижимости в различных регионах.

Гипотеза настоящего исследования состоит в предположении, что достичь указанных целей можно, если обучать нейронные сети на примерах поведения рынка недвижимости не одного отдельно взятого города, а сразу на нескольких городах, причем, помимо всей учитываемой в предшествующей работе (Yasnitsky, 2016) информации, сообщать нейронной сети сведения о географическом положении регионов, а также самих объектов недвижимости и связанный с этими данными уровень престижности и удобства места расположения объекта на географической карте города. Кроме того, предполагается проектировать нейронную сеть с учетом информации об экономическом состоянии каждого региона, к которому относится оцениваемый объект недвижимости.

## Методы

При построении математической модели региональных рынков недвижимости в каче-

стве входных параметров были введены географические, строительно-эксплуатационные, макроэкономические параметры и фактор времени.

Географические параметры: код города (1 — Москва, 2 — Санкт-Петербург, 3 — Екатеринбург, 4 — Новосибирск и т. д., всего 10 городов; географические координаты дома (широта, долгота), определяемые с помощью сервиса геокодирования «Яндекс.Карты»; показатель качества расположения дома.

Помимо кода города и географических координат, осуществляющих привязку объекта недвижимости к конкретному городу и месту на географической карте, авторами введен новый параметр, который назван показателем качества расположения дома. Этот параметр, по авторскому замыслу, должен сообщать нейронной сети информацию о степени престижности и удобства места расположения дома в городе.

Надо отметить, что в практике профессиональной оценки качество расположения объектов недвижимости обычно характеризуется расстоянием до цента города, транспортной доступностью, доступностью инфраструктуры (метро, парковок, городских скверов, деловых и культурных центров, промышленных индустриальных зон и т. д.). Однако, по мнению авторов, эти традиционно применяемые параметры имеют серьезный недостаток, заключающийся в том, что они зависят от субъективного мнения отдельных оценщиков. Например, встречаются города без ярко выраженного центра, или с несколькими центрами, а скверы, культурные и деловые центры, парковки различаются удобствами, объективно оценить которые часто не представляется возможным. То же самое можно сказать о возможностях учета негативного влияния на стоимость жилья близко расположенных промышленных предприятий,очных клубов, ресторанов, мест сбора и накопления отходов и т. д.

Для расчета предлагаемого показателя качества расположения дома используем так называемые статистические тепловые карты, построение которых осуществляется следующим образом.

На карту города наносятся координаты однотипных (близких по своим строительно-эксплуатационным характеристикам) объектов недвижимости, а их рыночная стоимость изображается на карте цветами. Зоны расположения наиболее дорогих объектов изображаются красным цветом, который по мере снижения стоимости объекта переходит в более холодные



**Рис. 1. Термическая карта ценовых зон города Екатеринбурга**

**Fig. 1. Heat map of the Ekaterinburg's price zones**

цветовые оттенки. Пример построенной таким способом статистической тепловой карты города Екатеринбурга приведен на рисунке 1.

Как видно на рисунке, Екатеринбург, по состоянию на зиму 2019 г. имеет четыре ярко выраженных ценовых центра, расположенных в разных частях города.

Далее строится математическая функция, приближенно аппроксимирующая значения цен квартир, изображенных на тепловой карте. Данная функция зависит от двух аргументов — географической широты и долготы места расположения дома. В нашем случае аппроксимирующая функция строится с помощью специально создаваемой для каждого города вспомогательной нейронной сети. Значение аппроксимирующей функции, выстраиваемой вспомогательной нейронной сетью, приведенное к интервалу от 0 до 1, задает параметр, названный авторами показателем качества расположения жилого дома. В ходе исследования доказано, что использование данного параметра повышает точность оценки квартир на 3–7 %.

Строительно-эксплуатационные факторы: тип стен дома (1 — блочные, 2 — шлакоблочные, 3 — деревянные, 4 — монолитные, 5 — газобетонные, 6 — панельные, 7 — кирпичные); количество комнат; этаж; количество этажей в доме; общая площадь квартиры; жилая площадь и площадь кухни.

Фактор времени: год и сезон (1 — зима, 2 — весна, 3 — лето, 4 — осень) на дату оценки стоимости квартиры.

Макроэкономические параметры: в качестве параметров, учитывающих внешнеэкономическую ситуацию в мире, стране и регионе, были выбраны: валютный курс доллара США по отношению к рублю; цена нефти

марки Brent, индекс валового внутреннего дохода ВВП; объем городского жилищного строительства в предшествовавшем году дате оценки; объем ипотечных кредитов, выданных в предшествовавшем году. Выбор этих параметров обусловлен тем, что они соответствуют нижнему уровню иерархии некоррелированных факторов укрупненной структуры ценобразующих факторов спроса и предложения рынка недвижимости [20]. Следует заметить, что в ходе построения нейросетевых моделей авторами исследовался вопрос использования большего числа параметров, таких как численность населения города, уровень доходов, индекс инфляции и др. Вычислительные эксперименты показали, что увеличение числа входных параметров приводило к эффекту автокорреляции и практически не приводило к росту ее точности. Другими словами, выбранные авторами макроэкономические параметры являются наиболее существенными и значимыми для моделирования рыночной стоимости.

Выходным параметром модели является заявленная рыночная цена объекта недвижимости.

Статистические данные о рынках недвижимости РФ, необходимые для обучения и тестирования нейронной сети, были собраны за период с 2006 г. по 2020 г., который охватывает как экономически спокойные для России годы, так и периоды экономического роста, кризисный и переломный этап российской и мировой экономики, период восстановления после кризиса и падение состояния экономики на фоне ввода санкций, резкого падения цен на нефть, финансовой блокады и закрытия доступа к международному капиталу.

В информационный базис вошли данные городов — административных центров федеральных округов РФ: Москва, Санкт-Петербург, Екатеринбург, Нижний Новгород, Новосибирск, Владивосток, Ростов-на-Дону, Пятигорск, и трех городов с населением выше миллиона — Хабаровск, Казань, Пермь. В дальнейшем планируется расширить область применения разработанной интеллектуальной системы на все города РФ и всего мира.

Очистка обучающего множества от случайных выбросов статистической информации произведена с применением авторской нейросетевой технологии, описанной в работе (Yasnitsky, 2020), позволившей отсечь 3,2 % некачественной собранной информации. Далее база была разделена на обучающее, валидирующее и тестирующее множества в пропорции: 70:20:10. Создание и обучение нейрон-

ных сетей производилось с помощью авторского программного обеспечения Nsim 5.0<sup>1</sup>, (доступ [www.LbAi.ru](http://www.LbAi.ru)). Для обучения нейронной сети и ее оптимизации использовалось соответственно обучающее и тестовое множество, а валидирующее — для проверки обобщающих свойств. Для оценки погрешности использовалась формула:

$$E = \frac{\sqrt{\sum_{n=1}^N (d_n - y_n)^2}}{N} \cdot \frac{100\%}{|\max(d_n) - \min(d_n)|}, \quad (1)$$

где  $N$  — количество элементов выборки;  $d_n$  — заявленная стоимость  $n$ -й квартиры;  $y_n$  — ее стоимость, оцененная с помощью нейронной сети. В окончательном варианте оптимальная структура нейронной сети представляла собой трехслойный персепtron с линейными входными и выходными нейронами. Первый скрытый слой содержал четыре нейрона, второй скрытый слой — три нейрона. Активационными функциями скрытых нейронов являлись функции гиперболического тангенса.

Погрешность нейронной сети, рассчитанная по формуле (1) на обучающем множестве составила 5,2 %, на тестовом множестве — 6,2 %, на валидирующем множестве — 6,3 %. Это является подтверждением того, что нейронная сеть усвоила закономерности рынков недвижимости выбранных Российских городов. Это значит, что нейронная сеть ведет себя так же, как вели бы себя моделируемые рынки недвижимости. Поэтому нейронную сеть можно использовать для изучения закономерностей рынков недвижимости городов РФ путем выполнения виртуальных компьютерных экспериментов, поочередно изменяя входные параметры и наблюдая за результатами вычислений — выходным параметром.

## Результаты

Моделирование рынков городской недвижимости проводилось путем проведения виртуальных компьютерных экспериментов на пяти типовых квартирах, различающихся количеством комнат и площадью, как указано в таблице 1.

Задаем строительно-эксплуатационные параметры дома, а также время оценки и соответствующую этому времени экономическую

<sup>1</sup> Нейросимулятор 5.0 : Свидетельство о государственной регистрации программы для ЭВМ № 2014618208 от 12.07.2014 г. / Черепанов Ф. М., Ясницкий Л. Н. (РФ).

Таблица 1  
Параметры, характеризующие рассматриваемые типовые квартиры

Table 1

Parameters characterizing the considered standard apartments

Номер квартиры	Количество комнат	Общая площадь, м <sup>2</sup>	Жилая площадь, м <sup>2</sup>	Площадь кухни, м <sup>2</sup>
1	1	30	18	6
2	2	55	32	9
3	3	80	50	12
4	4	106	70	14
5	5	145	75	16

Таблица 2

Фиксированные параметры, характеризующие время оценки и соответствующую экономическую ситуацию в России

Table 2

Fixed parameters characterising evaluation time and the corresponding economic situation in Russia

Параметр	Значение
Тип стен дома	7
Этаж	10
Количество этажей в доме	16
Год	2019
Сезон	1
Курс доллара США	63,62 руб.
Цена нефти марки Brent	3530 руб.
ВВП России	109 361 млрд руб.

ситуацию в мире, стране и регионе (табл. 2). Предполагаем, что это типовой шестнадцатиэтажный дом с кирпичными стенами и что квартиры расположены на 10-м этаже этого дома. Предполагаем также, что квартиры оценивались в начале 2019 г., зимой. На этот

момент курс американского доллара составлял 63,62 руб., цена нефти марки Brent — 3530 руб. за баррель, ВВП России — 109 361 млрд руб. Указанный набор параметров с соответствующими им значениями (или кодировкой) приведены в таблице 2.

На первом этапе моделирования задается исследуемый объект с реальными координатами и характеристиками типового дома и квартиры (табл. 3). Пусть выбранный для экспериментов дом находится в центральном районе города Москвы и имеет географические координаты: широта 55,75211 градусов, долгота 37,59398 градусов. Показатель качества расположения дома в указанном районе Москвы, вычисленный с помощью вспомогательной нейронной сети, составил 0,95. В году, предшествовавшем оценке, объем жилищного строительства в Москве составил 5025 тыс. м<sup>2</sup>, а объем ипотечного кредитования — 389 842 млрд руб.

Результаты оценки квартир, полученные с помощью нейронной сети, представлены графически в виде группы из пяти столбцов, расположенной слева на рисунке 2. На том же рисунке правее приведены результаты оценки тех же квартир в предположении, что они расположены в таком же доме при виртуальном перемещении этого дома в центральную часть Санкт-Петербурга, а затем в центральную часть Екатеринбурга.

В вычислительном эксперименте виртуальное перемещение дома осуществляется путем замены значений входных параметров модели, приведенных в таблице 3, на значения входных параметров, приведенных в таблице 4, а затем — в таблице 5, отно-

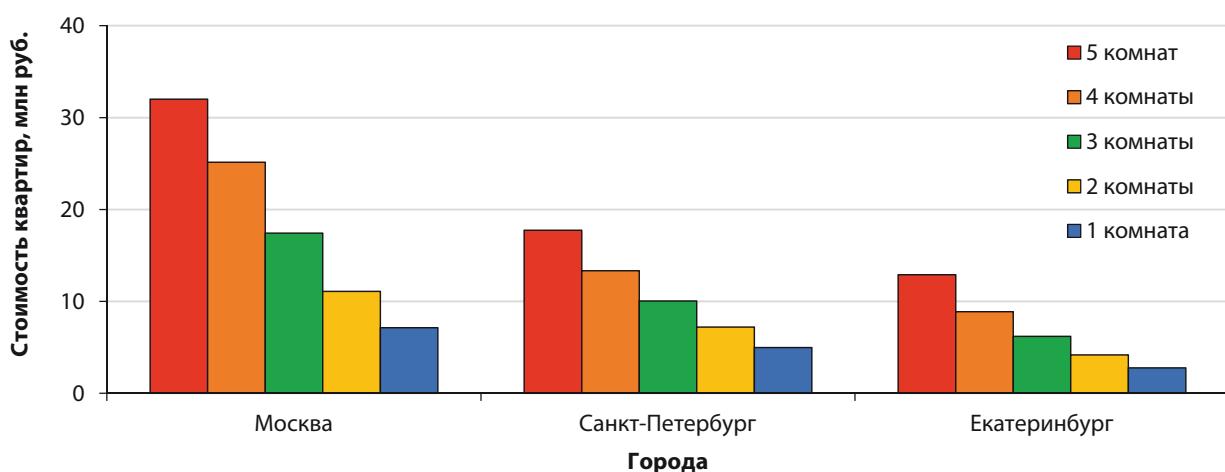


Рис. 2. Результаты компьютерных экспериментов по оценке стоимости пяти квартир при виртуальном перемещении типового шестнадцатиэтажного дома из Москвы в Санкт-Петербург и в Екатеринбург

Fig. 2. Results of computer experiments on appraisal of the market value of five apartments during the virtual movement of a typical sixteen-story building from Moscow to Saints Petersburg and to Ekaterinburg

Таблица 3

**Параметры, характеризующие выбранный для экспериментов типовой дом в Москве, его географическое положение и соответствующую экономическую ситуацию в регионе**

Table 3

**Parameters characterising a typical building in Moscow chosen for experiments, its geographic location and the corresponding economic situation in the region**

Параметр	Значение
Код города	1
Широта	55,75211°
Долгота	37,59398°
Показатель качества расположения дома	0,95
Жилищное строительство в регионе в предшествовавшем оценке году	5025 тыс. м <sup>2</sup>
Ипотечные кредиты в регионе предшествовавшем оценке году	389,842 млрд руб.

Таблица 4

**Параметры, характеризующие выбранный для экспериментов типовой дом в Санкт-Петербурге, его географическое положение и соответствующую экономическую ситуацию в регионе**

Table 4

**Parameters characterising a typical building in Saint-Petersburg chosen for experiments, its geographic location and the corresponding economic situation in the region**

Параметр	Значение
Код города	2
Широта	59,936927°
Долгота	30,315257°
Показатель качества расположения дома	0,95
Жилищное строительство в регионе в предшествовавшем оценке году	3471,2 тыс. м <sup>2</sup>
Ипотечные кредиты в регионе предшествовавшем оценке году	193,359 млрд руб.

Таблица 5

**Параметры, характеризующие выбранный для экспериментов типовой дом в Екатеринбурге, его географическое положение и соответствующую экономическую ситуацию в регионе**

Table 5

**Parameters characterising a typical building in Ekaterinburg chosen for experiments, its geographic location and the corresponding economic situation in the region**

Параметр	Значение
Код города	3
Широта	56,839114°
Долгота	60,606952°
Показатель качества расположения дома	0,95
Жилищное строительство в регионе в предшествовавшем оценке году	2391,1 тыс. м <sup>2</sup>
Ипотечные кредиты в регионе предшествовавшем оценке году	89,816 млрд руб.

сящихся соответственно к Санкт-Петербургу и Екатеринбургу.

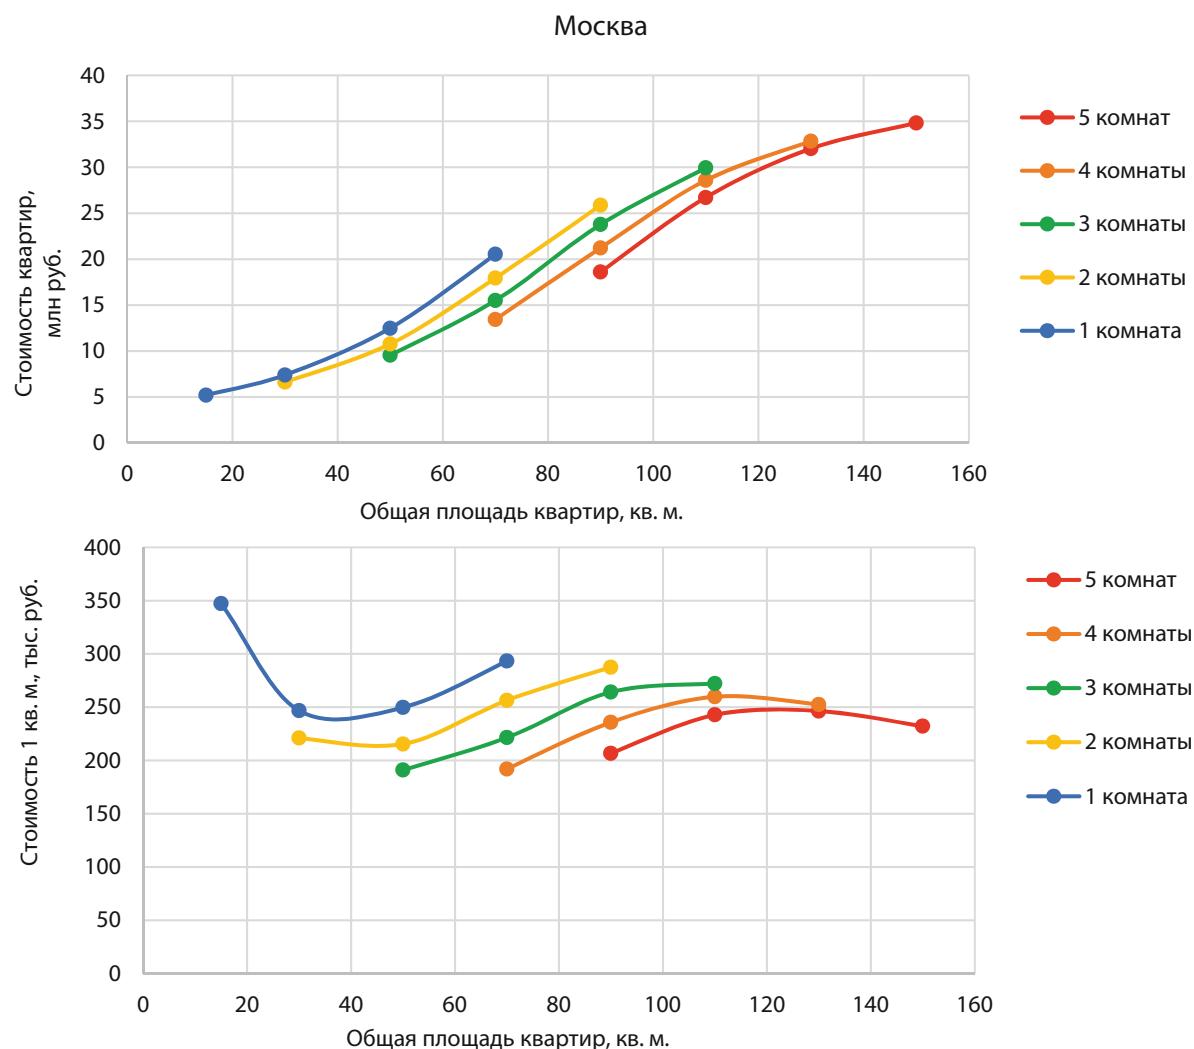
Как видно на рисунке 2, во всех трех городах цены квартир снижаются с уменьшением количества комнат и, соответственно, площади. Стоимость пятикомнатной квартиры в Москве больше стоимости аналогичной квартиры в Екатеринбурге в 2,48 раза, четырехкомнатной — в 2,83 раза, трехкомнатной — в 2,81 раза, двухкомнатной — в 2,65 раза, однокомнатной — в 2,57 раза.

Результаты проведенного сценарного прогноза, представленные на рисунке 2, демонстрируют адекватность в отражении специфики выбранных для исследований регионов. Москва, имея статус столицы, по своему благосостоянию, доходам населения, объемам инвестиций и другим показателям значительно превосходит остальные города. Санкт-Петербург — второй по величине город в России. Екатеринбург является менее крупным административным и торгово-промышленным центром, поэтому стоимости моделируемых квартир убывают по мере виртуального перемещении выбранного дома из Москвы в Санкт-Петербург и в Екатеринбург, что продемонстрировано на рисунке.

Следующая серия компьютерных экспериментов представлена на рисунках 3–5.

На рисунке 3 показано изменение стоимости пяти московских квартир при виртуальном увеличении их общих площадей и одновременном пропорциональном увеличении жилой площади и площади кухни. Снизу на том же рисунке показано изменение удельной стоимости квадратного метра площади рассматриваемых квартир. Как видно на рисунке, показатели стоимости всех пяти квартир равномерно возрастают с увеличением их площадей. Однако удельные стоимости одного квадратного метра площади квартир подчиняются иным закономерностям. Как видно на нижней части рисунка 3, самую высокую удельную стоимость квадратного метра в Москве имеет однокомнатная квартира минимальных размеров — 16 м<sup>2</sup>. Также видно, что максимальная стоимость двухкомнатной квартиры достигается при ее площади 90 м<sup>2</sup>, трехкомнатной — 100 м<sup>2</sup>, четырехкомнатной — 110 м<sup>2</sup>, пятикомнатной — 120 м<sup>2</sup>. Этот интересный экспериментальный факт, по-видимому, имеет смысл принимать во внимание при планировании строительства жилых объектов г. Москвы.

Далее, анализируя рисунки 4 и 5, на которых изображены результаты аналогичных вычислительных экспериментов, относящихся



**Рис. 3.** Зависимости стоимости квартир г. Москва (сверху) и удельной стоимости одного квадратного метра площади (снизу) от их общей площади

**Fig. 3.** Dependence of the Moscow apartment's market value (top) and the market value of one square meter (bottom) from their total area

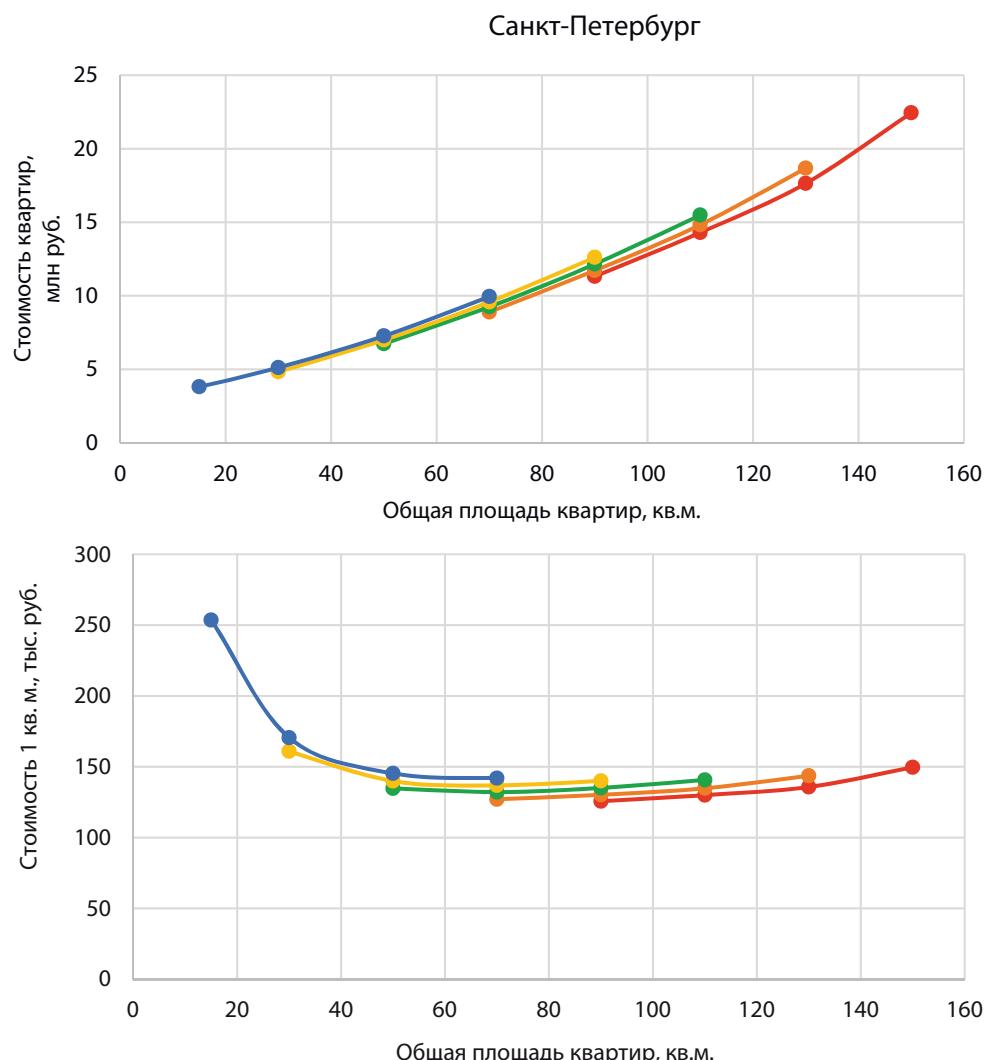
к Санкт-Петербургу (табл. 3) и Екатеринбургу (табл. 4), можно заметить, что для этих городов однокомнатная квартира площадью 16 м<sup>2</sup> по-прежнему остается в выигрыше с точки зрения застройщика. Стоимость квадратного метра ее площади по-прежнему максимальна.

Можно также заметить, что для Санкт-Петербурга стоимости одного квадратного метра двух-, трех-, четырех- и пятикомнатных квартир мало зависят от их общей площади и отличаются между собой не более чем в 1,20 раз, тогда как для Москвы это соотношение составляет 1,42 раз, а для Екатеринбурга — 1,31 раз. Для Екатеринбурга среди двухкомнатных квартир наибольшую стоимость квадратного метра имеют квартиры общей площадью 30 м<sup>2</sup>, среди трехкомнатных — 110 м<sup>2</sup>, среди четырехкомнатных — 130 м<sup>2</sup>, среди пятикомнатных — 150 м<sup>2</sup>.

Выявленный результат представляет практический интерес для застройщиков Екатеринбурга.

### Заключение

Предложен подход к созданию экономико-математических моделей массовой оценки жилых объектов, обладающих свойством самоадаптации к пространству и времени, пригодных для сравнительного анализа и выявления закономерностей и особенностей региональных рынков. Разработана комплексная экономико-математическая модель и компьютерная программа массовой оценки жилой недвижимости десяти городов РФ, учитывающая их географическое положение, уровень престижности и удобства места расположения квартиры в городе, строительно-эксплуатационные параметры дома и квартиры, а также текущее со-



**Рис. 4.** Зависимости стоимости квартир г. Санкт-Петербург (сверху) и удельной стоимости одного квадратного метра (снизу) от их площади

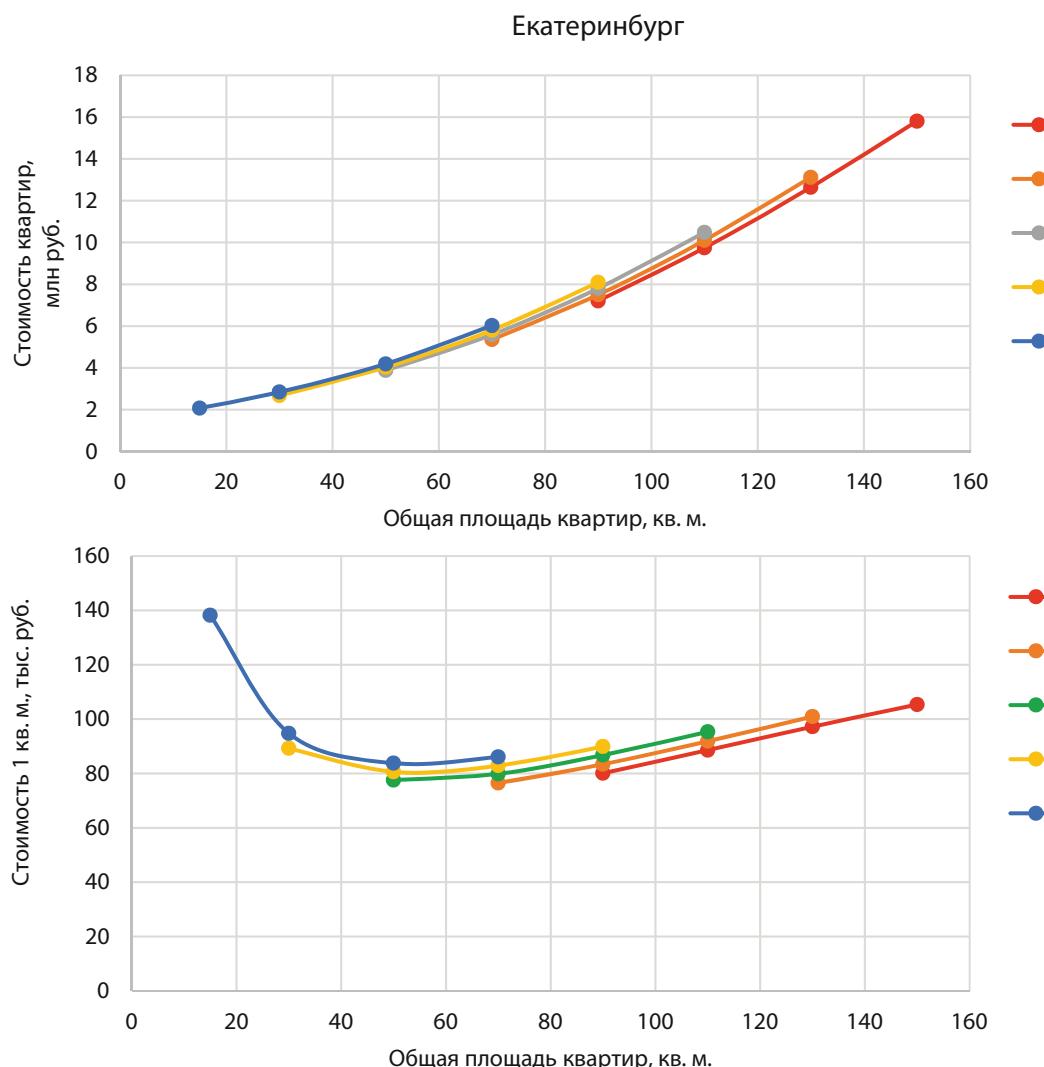
**Fig. 4.** Dependences of the Saint-Petersburg apartment's market value (top) and the market value of one square meter (bottom) from their total area

стояние экономики в регионе, в стране и в мире. Методом сценарного прогнозирования на примере пяти типовых квартир, выполнены сценарные прогнозы и исследования рынков Москвы, Санкт-Петербурга и Екатеринбурга. Показано, что рыночная стоимость различных квартир, расположенных в различных городах, по-разному реагирует на виртуальные изменения их площади. Получены зависимости изменения рыночной стоимости от ряда эксплуатационных показателей. Установлены особенности ценообразования удельной стоимости квадратного метра для объектов различных регионов при их различной площади.

Отличительной особенностью разработанной модели является свойство самоадаптируемости к постоянно меняющейся с течением времени экономической обстановке, а также возможность ее применения сразу ко многим

городам. Именно в этом состоят научная новизна и конкурентное преимущество развиваемого авторами подхода, реализация которого стала возможной благодаря предложенному в настоящей статье параметру, названному показателем качества расположения дома, и методике его расчета, а также благодаря применению авторской методики выявления и устранения выбросов статистической информации.

Учитывая низкую погрешность результатов моделирования, можно с некоторыми оговорками утверждать, что в настоящем исследовании удалось экспериментально доказать возможность построения единой математической модели, способной оценивать рыночную стоимость жилой недвижимости различных городов. Этот результат открывает путь другим исследователям для построения моделей отдельных регионов и всей страны в целом.



**Рис. 5.** Зависимости стоимости квартир г. Екатеринбург (сверху) и удельной стоимости одного квадратного метра (снизу) от их площади

**Fig. 5.** Dependences of the Ekaterinburg apartment's market value (top) and the market value of one square meter (bottom) from their total area

Полученные результаты имеют практическую значимость для строительной отрасли, в частности, разработанная модель и реализующая ее компьютерная программа востребованы государственными структурами, занимающимися вопросами управления рынком городской недвижимости, вопросами имущественного налогообложения, вопросами повышения эффективности рынка, а также строительными организациями в решении стратегических задач рыночного прогнозирования.

Разработанная интеллектуальная система доступна по ссылке <https://projects.permi.ru/Nedv>.

С помощью этого сервиса можно получить оценку стоимости любых квартир, расположенных в указанных десяти городах РФ, а также выполнить сценарные прогнозы и исследования рынков недвижимости этих городов, в частности, исследовать влияние на региональные рынки недвижимости ипотечных программ и макроиндексов.

### Список источников

- Анимица Е. Г., Власова Н. Ю. Градоведение. Екатеринбург : Изд-во Урал. гос. экон. ун-та, 2010. 433 с.
- Борусяк К. К., Мунерман И. В., Чижов С. С. Нейросетевое моделирование в задаче массовой оценки нежилой недвижимости г. Москвы // Экономическая наука современной России. 2009. № 4 (47). С. 86–98.
- Бочко В. С., Захарчук Е. А. Индивидуализация стратегий развития городов. На примере Екатеринбурга и Бирмингема // Экономика региона. 2020. Т. 16, вып. 2. С. 391–405. DOI: doi.org/10.17059/2020-2-5.

*Дьяков В. А., Курзаева Л. В., Вахрушев В. И.* Обзор методов построения моделей оценки недвижимости // Современная техника и технологии. 2016. № 11. Ч. 2. URL: <http://technology.sciencedirect.com/science/article/pii/S1068362316301137> (дата обращения: 15.09.2020).

*Молчанова М. Ю., Печенкина А. В.* Применение сценарного метода при прогнозировании ситуации на рынке жилья г. Перми // Вестник Пермского университета. «PermUniversityHerald. ECONOMY». 2015. № 1 (24). С. 79–88. (Экономика).

*Мунерман И. В.* Нейро-нечеткие модели и инструменты для регионального управления объектами коммерческой недвижимости: дисс. ... канд. экон. наук: 08.00.13. Москва, 2011. 156 с.

Пермская научная школа искусственного интеллекта и ее инновационные проекты / Л. Н. Ясицкий, В. В. Бондарь, С. Н. Бурдин и др. Москва — Ижевск : НИЦ «Регулярная и хаотическая динамика», 2008. 75 с.

*Родина С. М.* Использование метода нечеткой логики при оценке недвижимости. На примере жилья // Научно-технические ведомости Санкт-Петербургского государственного политехнического университета. Информатика. Телекоммуникации. Управление. 2009. Т. 91, вып. 6. С. 135–140.

*Стерник Г. М., Стерник С. Г.* Анализ рынка недвижимости для профессионалов. Москва : ЗАО «Издательство „Экономика“», 2009. 606 с.

Predicting property price index using artificial intelligence techniques: Evidence from Hong Kong / R. B. Abidoye, A. P. C. Chan, F. A. Abidoye, O. S. Oshodi // International Journal of Housing Markets and Analysis. 2019. No. 12 (6). P. 1072–1092. DOI: doi.org/10.1108/IJHMA-11-2018-0095.

*Abidoye R. B., Chan A. P. C.* Modelling property values in Nigeria using artificial neural network // Journal of Property Research. 2017. No. 34 (1). P. 36–53. DOI: doi.org/10.1080/09599916.2017.1286366.

An empirical analysis of simplified valuation approaches for residential property tax purposes / P. Davis, W. Mccluskey, T. V. Grissom, M. McCord // Property Management. 2012. No. 30 (3). P. 232–254. DOI: doi.org/10.1108/02637471211233774.

Assessment of the Real Estate Market Value in the European Market by Artificial Neural Networks Application / J. Ćetković, S. Lakić, M. Lazarovska, et al. // Complexity. 2018. 1472957. DOI: doi.org/10.1155/2018/1472957.

*Borst R. A.* Artificial neural networks in mass appraisal // Journal of Property Tax Assessment & Administration. 1995. No. 1 (2). P. 5–15.

*Borst R. A.* Artificial neural networks: the next modelling/calibration technology for the assessment community // Property Tax Journal. 1991. No. 10 (1). P. 69–94.

*Do A. Q., Grudnitski G.* A neural network approach to residential property appraisal // The Real Estate Appraiser. 1992. No. 58. P. 38–45.

*Evans A., James H., Collins A.* Artificial neural networks: An application to residential valuation in the UK // Journal of Property Valuation and Investment. 1991. No. 11 (2). P. 195–204.

*Guan J., Zurada J., Levitan A. S.* An adaptive neuro-fuzzy inference system based approach to real estate property assessment // Journal of Real Estate Research. 2008. No. 30 (4). P. 395–422. DOI: doi.org/10.1080/10835547.2008.12091225.

*Malaman C. S., Amorim A.* Method for determining values in real estate appraisal: Comparing between linear regression model and fuzzy logic // Boletim de Ciencias Geodesicas. 2017. No. 23 (1). P. 87–100. DOI: doi.org/10.1590/S1982-21702017000100006.

*Renigier-Biżozor M., Janowski A., d'Amato M.* Automated Valuation Model based on fuzzy and rough set theory for real estate market with insufficient source data // Land Use Policy. 2019. No. 87. P. 104021. DOI: dx.doi.org/10.1016/j.landusepol.2019.104021.

*Tay D. P., Ho D. K.* Artificial intelligence and the mass appraisal of residential apartments // Journal of Property Valuation and Investment. 1992. No. 10 (2). P. 525–540. DOI: doi.org/10.1108/14635789210031181.

Using geographically weighted regression for housing market segmentation / B. Manganelli, P. Pontrandolfi, A. Azzato, B. Murgante // International Journal of Business Intelligence and Data Mining. 2014. No. 9 (2). P. 161–177. DOI: dx.doi.org/10.1504/IJBIDM.2014.065100.

Using neural network model to estimate the rental price of residential properties / O. S. Oshodi, W. D. Thwala, T. B. Odubiyi, et al. // Journal of Financial Management of Property and Construction. 2019. No. 24 (2). P. 217–230. DOI: dx.doi.org/10.1108/JFMP-06-2019-0047.

*Xiao Y.* Hedonic Housing Price Theory Review. Urban Morphology and Housing Market (11–40). Singapore : Springer, 2017. 202 p. DOI: doi.org/10.1007/978-981-10-2762-8\_2.

*Yasnitsky L. N.* Algorithm for searching and analyzing abnormal observations of statistical information based on the Arnold — Kolmogorov — Hecht-Nielsen theorem // International Journal of Advanced Trends in Computer Science and Engineering. 2020. No. 9 (2). P. 1814–1819. DOI: dx.doi.org/10.30534/ijatcse/2020/139922020.

*Yasnitsky L. N., Yasnitsky V. L.* Technique of design for integrated economic and mathematical model for mass appraisal of real estate property. Study case of Yekaterinburg housing market // Journal of Applied Economic Sciences. 2016. No. 11 (8). P. 1519–1530.

## References

Abidoye, R. B. & Chan, A. P. C. (2017). Modelling property values in Nigeria using artificial neural network. *Journal of Property Research*, 34(1), 36–53. DOI: doi.org/10.1080/09599916.2017.1286366.

- Abidoye, R. B., Chan, A. P. C., Abidoye, F. A. & Oshodi, O. S. (2019). Predicting property price index using artificial intelligence techniques: Evidence from Hong Kong. *International Journal of Housing Markets and Analysis*, 12(6), 1072–1092. DOI: doi.org/10.1108/IJHMA-11-2018-0095.
- Animitsa, E. G. & Vlasova, N. Yu. (2010). *Gradovedenie [Urbanology]*. Ekaterinburg: Ural State University of Economics, 433. (In Russ.)
- Bochko, V. S. & Zacharchuk, E. A. (2020). Individualization of City Development Strategies: Case of Ekaterinburg and Birmingham). *Ekonomika regiona [Economy of region]*, 16(2), 391–405. DOI: doi.org/10.17059/2020-2-5. (In Russ.)
- Borst, R. A. (1991). Artificial neural networks: the next modelling/calibration technology for the assessment community. *Property Tax Journal*, 10(1), 69–94.
- Borst, R. A. (1995). Artificial neural networks in mass appraisal. *Journal of Property Tax Assessment & Administration*, 1(2), 5–15.
- Borusyak, K. K., Munerman, I. V. & Chizhov, S. S. (2009). Neural network modeling in the problem of mass appraisal of non-residential real estate in Moscow. *Ekonomicheskaya nauka sovremennoy Rossii [Economics of Contemporary Russia]*, 4(47), 86–98. (In Russ.)
- Ćetković, J., Lakić, S., Lazarevska, M., Žarković, M., Vujošević, S., Cvijović, J. & Gogić, M. (2018). Assessment of the Real Estate Market Value in the European Market by Artificial Neural Networks Application. *Complexity*, 2018, 1472957. DOI: doi.org/10.1155/2018/1472957.
- Davis, P., McCluskey, W., Grissom, T. V. & McCord, M. (2012). An empirical analysis of simplified valuation approaches for residential property tax purposes. *Property Management*, 30(3), 232–254. DOI: 10.1108/02637471211233774.
- Do, A. Q. & Grudnitski, G. (1992). A neural network approach to residential property appraisal. *The Real Estate Appraiser*, 58, 38–45.
- Dyakov, V. A., Kurzaeva, L. V. & Vakhrushev, V. I. (2016). Review of methods of construction of real estate valuation models. *Sovremennaya tekhnika i tekhnologii [Modern technics and technologies]*, 11(2). Retrieved from: <http://technology.snauka.ru/2016/11/11387> (Date of access: 15.09.2020). (In Russ.)
- Evans, A., James, H. & Collins, A. (1991). Artificial neural networks: An application to residential valuation in the UK. *Journal of Property Valuation and Investment*, 11(2), 195–204.
- Guan, J., Zurada, J. & Levitan, A. S. (2008). An adaptive neuro-fuzzy inference system based approach to real estate property assessment. *Journal of Real Estate Research*, 30(4), 395–422. DOI: doi.org/10.1080/10835547.2008.12091225.
- Malaman, C. S. & Amorim, A. (2017). Method for determining values in real estate appraisal: Comparing between linear regression model and fuzzy logic. *Boletim de Ciencias Geodesicas*, 23(1), 87–100. DOI: doi.org/10.1590/S1982-21702017000100006.
- Manganelli, B., Pontrandolfi, P., Azzato, A. & Murgante, B. (2014). Using geographically weighted regression for housing market segmentation. *International Journal of Business Intelligence and Data Mining*, 9(2), 161–177. DOI: dx.doi.org/10.1504/IJBIDM.2014.065100.
- Molchanova, M. Yu. & Pechenkina, A. V. (2015). Application of the scenario method for forecasting Perm housing market. *Vestnik Permskogo universiteta. Seriya: Ekonomika [Perm University Herald. Economy]*, 1(24), 79–88. (In Russ.)
- Munerman, I. V. (2011). *Neyro-nechetkie modeli i instrumenty dlya regionalnogo upravleniya obektami kommercheskoy nedvizimosti: diss. ...kand. ekon. nauk: 08.00.13 [Neuro-fuzzy models and tools for regional management of commercial real estate.. Thesis of Cand. Sci. (Econ.). 08.00.13]*. Moscow, 156. (In Russ.)
- Oshodi, O. S., Thwala, W. D., Odubiyi, T. B., Abidoye, R. B. & Aigbavboa, C. O. (2019). Using neural network model to estimate the rental price of residential properties. *Journal of Financial Management of Property and Construction*, 24(2), 217–230. DOI: dx.doi.org/10.1108/JFMP-06-2019-0047.
- Renigier-Biżozor, M., Janowski, A. & d'Amato, M. (2019). Automated Valuation Model based on fuzzy and rough set theory for real estate market with insufficient source data. *Land Use Policy*, 87, 104021. DOI: dx.doi.org/10.1016/j.landusepol.2019.104021.
- Rodina, S. M. (2009). Use of the fuzzy logic method in real estate appraisal. On the example of housing. *Nauchno-tehnicheskie vedomosti Sankt-Peterburgskogo gosudarstvennogo politekhnicheskogo universiteta. Informatika. Telekommunikatsii. Upravlenie [St. Petersburg Polytechnical University Journal. Computer Science. Telecommunication and Control Systems]*, 91(6), 135–140. (In Russ.)
- Sternik, G. M. & Sternik, S. G. (2009). *Analiz rynka nedvizimosti dlya professionalov [Analysis of the real estate market for professionals]*. Moscow: Izdatelstvo "Ekonomika", 606. (In Russ.)
- Tay, D. P. & Ho, D. K. (1992). Artificial intelligence and the mass appraisal of residential apartments. *Journal of Property Valuation and Investment*, 10(2), 525–540. DOI: doi.org/10.1108/14635789210031181.
- Xiao, Y. (2017). Hedonic Housing Price Theory Review. In: *Urban Morphology and Housing Market* (pp. 11–40). Singapore: Springer. DOI: doi.org/10.1007/978-981-10-2762-8\_2.
- Yasnitsky, L. N. & Yasnitsky, V. L. (2016). Technique of design for integrated economic and mathematical model for mass appraisal of real estate property. Study case of Yekaterinburg housing market. *Journal of Applied Economic Sciences*, 11(8), 1519–1530.
- Yasnitsky, L. N. (2020). Algorithm for searching and analyzing abnormal observations of statistical information based on the Arnold — Kolmogorov — Hecht-Nielsen theorem. *International Journal of Advanced Trends in Computer Science and Engineering*, 9(2), 1814–1819. DOI: doi.org/10.30534/ijatcse/2020/139922020.

Yasnitsky, L. N., Bondar, V. V., Cherepanov, F. M., Burdin, S. N., Volegova, E. V., Gladkiy, S. L., ... Shipitsyn, P. A. (2008). *Permskaya nauchnaya shkola iskusstvennogo intellekta i ee innovatsionnye proekty* [Perm Scientific School of Artificial Intelligence and Its Innovative Projects]. Moscow — Izhevsk: SIC Regular and Chaotic Dynamics, 75. (In Russ.)

### Информация об авторах

**Ясницкий Леонид Нахимович** — доктор технических наук, профессор, председатель, Пермское отделение Научного совета при Президиуме РАН по методологии искусственного интеллекта, профессор кафедры информационных технологий в бизнесе, НИУ «Высшая школа экономики» в Перми; профессор кафедры прикладной математики и информатики, Пермский государственный национальный исследовательский университет; Scopus Author ID: 6602291952; <https://orcid.org/0000-0002-8212-3826>; SPIN РИНЦ: 9529-0668, Author ID: 3277 (Российская Федерация, 614107, г. Пермь, ул. Лебедева, 27; 614990, г. Пермь, ул. Букирева, 15; e-mail: yasn@psu.ru).

**Ясницкий Виталий Леонидович** — кандидат экономических наук, доцент кафедры строительного инжиниринга и материаловедения, Пермский национальный исследовательский политехнический университет; Scopus Author ID: 57192961381; <https://orcid.org/0000-0002-8881-533X>; SPIN РИНЦ: 6754-2911 (Российская Федерация, 614990, г. Пермь, Комсомольский проспект, 29; e-mail: yasnitskiy@mail.ru).

**Алексеев Александр Олегович** — кандидат экономических наук, доцент, доцент кафедры строительного инжиниринга и материаловедения, Пермский национальный исследовательский политехнический университет; Scopus Author ID: 55972134400; <https://orcid.org/0000-0001-5033-6694>; SPIN РИНЦ: 3350-9048 (Российская Федерация, 614990, г. Пермь, Комсомольский проспект, 29; e-mail: alekseev@cemps.pstu.ru).

### About the authors

**Leonid N. Yasnitsky** — Dr. Sci. (Eng.), Full Professor, Chairman of the Perm Branch of the Scientific Council under the Presidium of RAS on the Methodology of Artificial Intelligence; Professor, Department of Information Technologies in Business, National Research University “Higher School of Economics” in Perm; Professor, Department of Applied Mathematics and Computer Science, Perm State University; Scopus Author ID: 6602291952; <https://orcid.org/0000-0002-8212-3826>; SPIN RSCI: 9529-0668; Author ID: 3277 (27, Lebedeva St., Perm, 614107; 15, Bukireva St., Perm, 614990, Russian Federation; e-mail: yasn@psu.ru).

**Vitaliy L. Yasnitsky** — Cand. Sci. (Econ.), Associate Professor, Department of Construction Engineering and Materials Science, Perm National Research Polytechnic University; Scopus Author ID: 57192961381; <https://orcid.org/0000-0002-8881-533X>; SPIN RSCI: 6754-2911 (29, Komsomolskiy Ave., Perm, 614990, Russian Federation; e-mail: yasnitskiy@mail.ru).

**Aleksandr O. Alekseev** — Cand. Sci. (Econ.), Associate Professor, Department of Construction Engineering and Materials Science, Perm National Research Polytechnic University; Scopus Author ID: 55972134400; <https://orcid.org/0000-0001-5033-6694>; SPIN RSCI: 3350-9048 (29, Komsomolskiy Ave., Perm, 614990, Russian Federation; e-mail: alekseev@cemps.pstu.ru).

Дата поступления рукописи: 25.09.2020.

Прошла рецензирование: 29.12.2020.

Принято решение о публикации: 07.04.2022.

Received: 25 Sep 2020.

Reviewed: 29 Dec 2020.

Accepted: 07 Apr 2022.