

Д.А. Масленников, Л.Ю. Катаева, М.Н. Ильичёва

**КОМПЛЕКСНОЕ ПРОГНОЗИРОВАНИЕ
ЭКОНОМИЧЕСКОГО РАЗВИТИЯ
НИЖЕГОРОДСКОЙ ОБЛАСТИ: ИНТЕГРАЦИЯ
ЧИСЛЕННЫХ МЕТОДОВ И МАШИННОГО ОБУЧЕНИЯ**

Нижегородский государственный технический университет
им. Р.Е. Алексеева
Нижний Новгород, Россия

Разработана эконометрическая модель для прогнозирования ключевых социально-экономических показателей на региональном уровне. На основе статистических данных по субъектам Российской Федерации реализована методология, включающая многоэтапную предобработку данных: нормализацию относительно федеральных значений, логарифмирование для снижения асимметрии распределений, робастное усечение выбросов и импутацию пропущенных значений. Модель построена на основе множественной линейной регрессии с включением лаговых переменных для учета временной динамики. В качестве предикторов использованы ретроспективные данные из различных секторов экономики, включая промышленное производство, здравоохранение, уровень жизни и строительство. Результаты демонстрируют высокую предсказательную способность модели: коэффициенты корреляции между фактическими и прогнозными значениями для ряда целевых индикаторов составляют от 68,80 до 81,60 %. Дополнительно установлено, что интеграция классических эконометрических процедур с элементами машинного обучения и робастной статистики повышает устойчивость оценок и снижает чувствительность модели к локальным выбросам. Предложенный подход обеспечивает адаптивность к структурным изменениям и позволяет учитывать комплексное взаимодействие макроэкономических и демографических факторов. Полученные результаты подтверждают применимость модели для анализа региональной динамики, стратегического планирования и обоснования социально-экономической политики в условиях высокой неопределенности и пространственной неоднородности российской экономики.

Ключевые слова: численное моделирование, машинное обучение в экономике, эконометрическое моделирование, прогнозирование, региональная экономика.

Введение. Экономическая система XXI в. характеризуется высокой скоростью изменений: на траекторию развития отраслей влияют как глобальные кризисы и технологические прорывы, так и региональная специфика и социальные трансформации. В таких условиях качественные про-

гнозы превращаются в критически важный инструмент формирования макроэкономической политики, стратегического менеджмента и оценки инвестиционных рисков [1-4]. Решение задачи регионального прогнозирования, являясь неотъемлемой частью экономического анализа, обеспечивает обоснованность решений в условиях неопределенности и нестабильной конъюнктуры.

Одним из ключевых аргументов в пользу точного прогнозирования выступает необходимость оперативного реагирования на внезапные шоки – экономические кризисы, ценовые колебания на энергетических рынках, изменения в мировой торговле и финансовой системе. Актуализация прогнозов позволяет своевременно корректировать экономические стратегии, выявлять потенциальные угрозы, снижать риски и оптимально распределять ресурсы. Это особенно важно для стран с выраженным региональным многообразием (Россия, США, Китай и др.), где отраслевые структуры регионов существенно различаются [5].

Корректные прогнозы повышают прозрачность экономических процессов. Правительственные и корпоративные субъекты, располагая надежными оценками будущих тенденций, способны точнее формировать бюджеты, проектировать программы поддержки и настраивать монетарную политику. Доверие инвесторов и устойчивость экономической системы напрямую зависят от точности предсказаний [1, 2]. Нелинейные взаимосвязи, структурные сдвиги и высокоразмерные данные обуславливают необходимость дальнейшего совершенствования методик прогнозирования. Процессы цифровизации, глобализации и технологической инновации усиливают сложность задач: разработанные десятки лет назад модели уже не отражают реалии турбулентной экономики. Классические подходы требуют радикальной модернизации, в том числе, внедрения анализа больших данных и поиска скрытых нелинейных закономерностей [5-8].

Прорывы в машинном обучении и гибридных методах открывают новые горизонты повышения точности экономических прогнозов. Глубокие нейронные сети, ансамблевые алгоритмы и модели с автоматизированным отбором признаков позволяют обрабатывать колоссальные массивы информации, выявлять сложные паттерны и быстро адаптироваться к структурным изменениям. Ряд исследований демонстрирует, что такие методы превосходят традиционные модели по точности и гибкости [5-8]. Таким образом, методология экономического прогнозирования претерпевает кардинальные изменения, становясь одной из центральных проблем современной экономической науки.

Потребность в эффективных прогнозах обусловлена не только желанием «заглянуть в будущее», но и необходимостью выстраивать устой-

чивые стратегии развития, управлять рисками и обеспечивать экономическую стабильность на фоне глобальных и локальных вызовов.

Российская экономика обладает ярко выраженной сырьевой зависимостью: колебания мировых цен на нефть и газ, а также общая конъюнктура глобального рынка оказывают прямое воздействие на макро- и микроэкономические показатели страны. В связи с этим, универсальные зарубежные инструменты анализа и прогнозирования часто дают искаженные результаты, что обосновывает необходимость разработки национальных моделей, учитывающих специфику цифровой экономики и особенности регионального разнообразия [4, 5, 9].

В отечественной литературе подчеркивается, что синергия классических эконометрических методов и алгоритмов машинного обучения повышает прогностическую валидность моделей [9-11]. Такой гибридный подход объединяет ретроспективный анализ исторических трендов и учет новых экзогенных факторов, что критически важно для разработки сбалансированных мер государственной политики и долгосрочных стратегий социально-экономического развития.

Предобработка данных, включающая нормализацию (масштабирование, логарифмирование, стандартизацию) и селекцию признаков, играет ключевую роль в построении надежных моделей: нормализация обеспечивает сопоставимость разноразмерных характеристик, а регуляризаторы типа LASSO автоматизируют отбор наиболее информативных переменных, снижая риск переобучения и вычислительную нагрузку [12-14]. В этой работе особое внимание удалено именно корректной нормализации и фильтрации без понижения размерности.

Регрессионный анализ сохраняет свою актуальность благодаря экономической интерпретируемости коэффициентов, однако внедрение динамических компонентов – лаговых переменных в рамках ARDL-моделей или моделей с распределенными лагами – существенно увеличивает точность и устойчивость прогноза [1-3]. Основная модель исследования построена с учетом статистически значимых лагов, что обеспечивает ее robustность.

Для оценки неопределенности прогнозов применяется бутстрэп-ресемплирование, позволяющее рассчитывать доверительные интервалы без строгих предпосылок о распределении ошибок и одновременно учитывать выборочную и модельную неопределенность. В данном исследовании метод бутстрэп интегрирован в процедуру кросс-валидации и служит проверкой стабильности параметров [1, 15].

Анализ временных рядов традиционно строится на моделях ARIMA и ARIMAX, требующих стационарности данных и ограниченного числа переменных [2, 16]. Для комплексного учета взаимовлияния

макроэкономических индикаторов отечественная практика внедряет векторные авторегрессии VAR и их модификации, такие как VAR-LASSO, позволяющие бороться с «проклятием размерности» [2, 3]. В рассматриваемом исследовании динамика отражена через включение лаговых переменных, что соответствует идеям VAR-подхода, хоть и без полной реализации векторной системы [3, 8].

Таким образом, комплексная методология, объединяющая особенности российской экономики, современные машины обучения и строгие эконометрические процедуры, создает надежную платформу для высокоточного прогнозирования и разработки обоснованных экономических стратегий.

В экономическом прогнозировании все заметнее роль методов машинного обучения: глубокие нейронные сети, ансамбли и схемы обучения с подкреплением позволяют фиксировать сложные нелинейные закономерности, которые классические эконометрические конструкции описывают лишь частично [6-8]. Наиболее убедительные результаты демонстрируют гибридные модели, совмещающие традиционные эконометрические инструменты с ML-алгоритмами: их прогностическая точность превосходит как линейные, так и нелинейные аналоги сугубо классического типа [4, 6-8]. Особенno эффективны такие подходы при работе с «большими данными», где стандартная эконометрика сталкивается с проблемой избыточной размерности; в настоящем исследовании применены элементы машинного обучения – регуляризация и автоматизированный отбор признаков, что повышает устойчивость оценок без потери экономической трактуемости. Современные публикации свидетельствуют: методологический фокус сместился к комплексным системам, объединяющим продвинутые процедуры нормализации, строгий выбор значимых переменных, бутстрэп-оценку, анализ временных рядов и ML-компоненты. Такой синтез позволяет учитывать волатильность и структурные разрывы, существенно улучшая качество предсказаний. Существенное внимание уделяется адаптации зарубежных методик к специфике российской экономики, чему посвящен ряд отечественных работ [5, 8-11, 16, 17]. В итоге повышение точности прогнозов превращается в ключевой фактор как для оперативного управления, так и для формирования долгосрочной социально-экономической политики.

Методы. Методологические подходы к прогнозированию играют важнейшую роль в расширении концептуальных границ анализа, что особенно важно в современных условиях неопределенности. В рамках данного исследования особое внимание уделялось интеграции мультифакторных индикаторов и построению адаптивных моделей, позволяющих учитывать как структурные, так и динамические трансформации социально-экономи-

ческих процессов. Применение инновационных методов обработки данных, таких как многоуровневое нормирование, логарифмирование, последующая стандартизация обеспечило создание единого аналитического пространства для сопоставления региональных показателей с федеральными. Такой междисциплинарный подход способствует выявлению тонких корреляционных связей, повышая достоверность прогнозных оценок и улучшая качество управленческих решений в условиях глобальных экономических изменений.

В работе использовались ежегодные панели статистических данных по всем субъектам федерации, охватывающие широкий спектр абсолютных и относительных социально-экономических показателей. В соответствии с методологическими рекомендациями государственной статистики, показатели были классифицированы по признаку аддитивности: аддитивные показатели, для которых суммы по регионам позволяют получить федеральное значение, возможно с приемлемой погрешностью (например, валовой региональный продукт, ВРП), – и неаддитивные, для которых итоговое всероссийское значение рассчитывается с учетом особенностей алгоритмов и источников данных, а не простым суммированием. Для обеспечения сопоставимости региональных данных произведена корректировка аддитивных индикаторов на показатель среднегодовой численности населения субъекта Российской Федерации. Указанный методический подход нивелирует демографический масштаб и формирует единую систему интерпретации показателей в разрезе отклонения от средних по Российской Федерации значений с учетом размерности региона.

Дальнейшая нормализация проходила в два этапа. Сначала каждое региональное значение соотносили с федеральным уровнем того же года, тем самым переводя показатель в безразмерную форму: для аддитивных переменных это отражало долю региона в общенациональном показателе, а для неаддитивных – степень отклонения регионального значения от усредненной по стране.

Исходные ряды проявляли заметный правый «тяжелый хвост» и высокую дисперсию, поэтому для смягчения влияния экстремальных наблюдений каждое значение переводили в натуральный логарифм. После логарифмирования практиковалось мягкое усечение: если отклонение точки данных от среднего уровня, рассчитанного внутри промежутка между десятым и девяностым процентилями, превосходило четырехкратное стандартное отклонение той же усеченной выборки, значение поднимали к границе допустимого диапазона. Проверка тестом Шапиро-Уилка и Q-графиками показала, что распределения после такой процедуры стали близки к нормальному, при этом естественная вариабельность не была утрачена.

Временная составляющая была представлена через лаги: для каждого показателя сохранялись значения за предыдущие годы, что позволяло улавливать инерционные и отложенные эффекты. В случаях, когда в лаговых предикторных переменных встречались отдельные пропуски, применялась импутация средним значением по доступным наблюдениям данного региона, что сохраняло региональную специфику показателей. При полном отсутствии данных самого первого лага использовался средний уровень по стране как начальная точка анализа (что соответствовало нулевому значению с учетом всех выполненных этапов нормализации данных). Данный подход был выбран с учетом разнородности используемых показателей и обеспечивал необходимую целостность временных рядов при минимальном искажении результатов моделирования. Импутация применялась исключительно к предикторным переменным, что соответствует общепринятой эконометрической практике работы с панельными данными.

На завершающем шаге все текущие и лаговые переменные стандартизировали, вычитая их выборочное среднее и деля на выборочное стандартное отклонение. Благодаря этому, каждая переменная получила единый масштаб, а коэффициенты регрессионной модели стали напрямую сопоставимы. Очищенные, нормализованные, логарифмированные и стандартизованные данные легли в основу множественной линейной регрессии. Вектор признаков включал как актуальные, так и лаговые показатели, а качество модели контролировалось коэффициентом корреляции между фактическими и прогнозными значениями на обучающей и валидационной подвыборках. Сочетание раздельного учета федеральной и региональной динамики, двухэтапной нормализации, логарифмического сглаживания с робастным усечением, формирования лагов, простой импутации пропусков и окончательной стандартизации обеспечило статистическую устойчивость оценок и позволило надежно выявить взаимное влияние ключевых социально-экономических факторов на уровне российских регионов.

Результаты исследования и их обсуждение. В табл. 1 представлены результаты прогнозирования ряда показателей, подчеркивающие системный характер взаимосвязей в социально-экономической сфере. Несмотря на высокую предсказуемость ряда целевых индикаторов (коэффициенты корреляции варьируются в диапазоне от 68,80 до 81,60 %), влияние каждого отдельного предиктора оказывается сравнительно невелико и составляет от 16,39 до 19,84 %. Это явление отражает фундаментальную особенность экономических процессов – их мультифакторную природу, при которой множество различных факторов вносят небольшой, но значимый вклад в формирование итоговых показателей.

*Таблица 1.***Сравнительный анализ прогнозируемых
и влияющих индикаторов различных секторов**

Название группы индикаторов	Наиболее прогнозируемый индикатор из данной группы	Коэффициент корреляции индикатора и прогноза	Наиболее влиающий индикатор на данный	Корреляция влияющего и целевого индикатора
Производство и импорт важнейших видов продукции для строительной деятельности	Производство стекла листового термически полированного и стекла листового с матовой или полированной поверхностью, но не обработанного другим способом	81,60 %	Производство пиломатериалов лиственных пород по федеральным округам Российской Федерации	19,16 %
Здравоохранение	Число больничных коек	69,25 %	Численность ординаторов и ассистентов-стажеров: Численность ординаторов	16,39 %
Уровень жизни населения	Реальные денежные доходы: Реальная начисленная заработка плата работников организаций	68,80 %	Производство материалов рулонных кровельных и гидроизоляционных по федеральным округам Российской Федерации	16,46 %
Жилищное и социально-культурное строительство	Ввод в действие жилых домов, построенных населением	78,59 %	Коэффициенты демографической нагрузки: старше трудоспособного возраста	19,42 %

Источник: результаты, полученные на основе авторского метода

Наиболее ярко эта закономерность проявляется в анализе производства строительных материалов. Например, производство листового стекла характеризуется высокой предсказуемостью (81,60 %), однако вклад в модель такого важного предиктора, как производство пиломатериалов лиственных пород, составляет лишь 19,16 %. Это свидетельствует о том, что производство стекла зависит от сложного комплекса факторов, включающего спрос со стороны жилищного и коммерческого строительства, региональную инвестиционную активность, логистические цепочки поставок, энергетические затраты и технологические инновации. Аналогичная ситуация наблюдается и в производстве силикатных блоков, где предсказуемость достигает 79,79 %, а влияние реальной заработной платы – 19,84 %.

Здесь доходы населения выступают индикатором общей экономической активности, однако производство строительных материалов также чувствительно к государственным программам, отраслевому регулированию и инвестиционному климату. Взаимосвязь между вводом жилых домов, построенных населением, и демографической нагрузкой старшего поколения (предсказуемость 78,59 %, влияние 19,42 %) отражает глубокие социально-экономические процессы. Старшее поколение часто становится источником финансирования индивидуального строительства для молодых семей, а регионы с высокой долей пожилого населения демонстрируют специфические паттерны жилищного строительства. Демографическая структура, таким образом, оказывает существенное влияние на региональные приоритеты развития инфраструктуры. Показатель реальной заработной платы с предсказуемостью 68,80 %, связан с производством кровельных материалов (влияние 16,46 %), что указывает на комплексную взаимосвязь между уровнем жизни населения и строительной активностью. Уровень заработной платы формируется под воздействием множества факторов, включая производительность труда в ключевых отраслях, инфляционные процессы, налоговую политику, региональные программы развития и структурные изменения в экономике.

В сфере здравоохранения показатель числа больничных коек (предсказуемость 69,25 %) при умеренном влиянии численности ординаторов (16,39 %) отражает сложность медицинской инфраструктуры. На обеспеченность медицинскими ресурсами влияют государственные программы, демографические тренды, региональные особенности заболеваемости, финансирование отрасли и технологические изменения.

Таким образом, проведенный анализ подтверждает необходимость применения комплексных многофакторных моделей при прогнозировании социально-экономических показателей. Высокая предсказуемость при относительно слабом влиянии отдельных факторов свидетельствует о сложной системе взаимосвязей, где устойчивые экономические тренды формируются совокупным воздействием множества факторов. Это подчеркивает важность системного подхода и учета широкого спектра переменных для адекватного понимания и прогнозирования социально-экономических процессов.

Методологически это подчеркивает важность интеграции различных источников данных и применения системного подхода к построению прогностических моделей, что позволяет повысить их устойчивость и адаптивность к изменяющимся условиям. Результаты также демонстрируют, что для адекватного прогнозирования социально-экономических явлений необходимо учитывать не только прямые отраслевые показатели, но и косвенные факторы, такие как демографические тенденции, уровень доходов и региональные особенности.

В целом полученные выводы подтверждают, что многофакторное прогнозирование с использованием корреляционного анализа и комплекс-

ных моделей является эффективным инструментом для анализа и предсказания социально-экономических процессов. Это создает основу для разработки обоснованных управленческих решений и стратегий, направленных на устойчивое развитие регионов и отраслей экономики в условиях высокой неопределенности и динаминости внешней среды.

© Масленников Д.А., Кагаева Л.Ю., Ильичёва М.Н., 2025

Поступила в редакцию 13.10.2025

Принята к публикации 10.11.2025

Библиографический список

- [1] Chernick M.R. *Bootstrap Methods: A Guide for Practitioners and Researchers*. New York: Wiley; 2020. 378 p.
- [2] Hyndman R.J., Athanasopoulos G. *Forecasting: Principles and Practice*. 3rd ed. Melbourne: OTexts; 2021. 380 p.
- [3] Yang Y. et al. Machine Learning for Economic Forecasting: An Application to China's GDP Growth. arXiv preprint arXiv:2407.03595; 2024. Available from: <https://doi.org/10.48550/arXiv.2407.03595>.
- [4] Giannone D., Reichlin L., Small D. Nowcasting: The Real-Time Informational Content of Macroeconomic Data. *Journal of Monetary Economics*. 2008. Vol. 55 (4). pp. 665-676. Available from: <https://doi.org/10.1016/j.jmoneco.2008.05.010>.
- [5] Liang H., Zeng H., Dong X. Regional Economic Forecast Using Elman Neural Networks with Wavelet Function. *PLOS ONE*. 2024. Vol. 19 (3): e0299657. Available from: <https://doi.org/10.1371/journal.pone.0299657>.
- [6] Bajari P. et al. Machine Learning Methods for Demand Estimation. *American Economic Review*. 2015. Vol. 105 (5). pp. 481-485. Available from: <https://doi.org/10.1257/aer.p20151021>.
- [7] Hastie T. et al. The Elements of Statistical Learning: Data Mining, Inference and Prediction. *The Mathematical Intelligencer*. 2005. Vol. 27 (2). pp. 83-85. Available from: <https://doi.org/10.1007/BF02985802>.
- [8] Belloni A., Chernozhukov V., Hansen C. High-Dimensional Methods and Inference on Structural and Treatment Effects. *Journal of Economic Perspectives*. 2014. Vol. 28 (2). pp. 29-50. Available from: <https://doi.org/10.1257/jep.28.2.29>.
- [9] Diebold F.X., Mariano R.S. Comparing Predictive Accuracy. *Journal of Business & Economic Statistics*. 2002. Vol. 20 (1). pp. 134-144. Available from: <https://doi.org/10.1198/073500102753410444>.
- [10] Imbens G.W., Rubin D.B. *Causal Inference in Statistics, Social, and Biomedical Sciences*. Cambridge: Cambridge University Press; 2015. 625 p.
- [11] Shiller R.J. *Irrational Exuberance: Revised and Expanded Third Edition*. New York: Princeton University Press; 2016. 392 p.
- [12] Hamilton J.D. *Time Series Analysis*. Princeton: Princeton University Press; 2020. 816 p.
- [13] James G., Witten D., Hastie T., Tibshirani R. *An Introduction to Statistical Learning: With Applications in R*. 2nd ed. New York: Springer; 2021. 607 p.
- [14] Wooldridge J.M. *Introductory Econometrics: A Modern Approach*. 7th ed. Boston: Cengage Learning; 2020. 878 p.

-
- [15] Goodfellow I. et al. Deep Learning. Cambridge: MIT Press; 2016.
 - [16] Hyndman R.J., Athanasopoulos G. Forecasting: Principles and Practice. 3rd ed. Melbourne: OTexts; 2021. 442 p.
 - [17] Ashuri B., Lu J. Time Series Analysis of the ENR Construction Cost Index. Journal of Construction Engineering and Management. 2010. Vol. 136 (12). pp. 1289-1299. Available from: [https://doi.org/10.1061/\(ASCE\)CO.1943-7862.0000242](https://doi.org/10.1061/(ASCE)CO.1943-7862.0000242).

D.A. Maslennikov, L.Yu. Kataeva, M.N. Iliicheva

COMPLEX FORECASTING OF ECONOMIC DEVELOPMENT OF THE NIZHNY NOVGOROD REGION: INTEGRATION OF NUMERICAL METHODS AND MACHINE LEARNING

Nizhny Novgorod State Technical University n.a. R.E. Alekseev
Nizhny Novgorod, Russia

Abstract. The study is devoted to the development of an econometric model for forecasting key socio-economic indicators at the regional level. Based on statistical data from the constituent entities of the Russian Federation, a methodology was implemented that includes multi-stage data preprocessing: normalization relative to federal values, logarithmic transformation to reduce distribution asymmetry, robust outlier trimming, and imputation of missing values. The model is constructed using multiple linear regression with the inclusion of lagged variables to account for temporal dynamics. Retrospective data from various sectors of the economy – including industrial production, healthcare, living standards, and construction – were used as predictors. The results demonstrate a high predictive ability of the model: correlation coefficients between actual and predicted values for the analyzed target indicators range from 68.80 to 81.60 %. It was additionally established that the integration of classical econometric procedures with elements of machine learning and robust statistics increases the stability of estimates and reduces the model's sensitivity to local outliers. The proposed approach ensures adaptability to structural changes and captures the complex interaction between macroeconomic and demographic factors. The findings confirm the applicability of the developed methodology for analyzing regional dynamics, supporting strategic planning, and substantiating socio-economic policy decisions under conditions of high uncertainty and spatial heterogeneity of the Russian economy.

Key words: numerical modeling, machine learning in economics, econometric modeling, forecasting, regional economy.

References

- [1] Chernick M.R. Bootstrap Methods: A Guide for Practitioners and Researchers. New York: Wiley, 2017. 378 p.

-
- [2] Hyndman R.J., Athanasopoulos G. Forecasting: Principles and Practice. 3rd ed. Melbourne: OTexts, 2021. 380 p.
 - [3] Yang Y. et al. Machine Learning for Economic Forecasting: An Application to China's GDP Growth. arXiv preprint arXiv:2407.03595. 2024. DOI: 10.48550/arXiv.2407.03595
 - [4] Giannone D., Reichlin L., Small D. Nowcasting: The Real-Time Informational Content of Macroeconomic Data // Journal of Monetary Economics. 2008. Vol. 55. No. 4. pp. 665-676. DOI: 10.1016/j.jmoneco.2008.05.010
 - [5] Liang H., Zeng H., Dong X. Regional Economic Forecast Using Elman Neural Networks with Wavelet Function // PLOS ONE. 2024. Vol. 19. No. 3. pp. e0299657. DOI: 10.1371/journal.pone.0299657
 - [6] Bajari P. et al. Machine Learning Methods for Demand Estimation // American Economic Review. 2015. Vol. 105. No. 5. pp. 481-485. DOI: 10.1257/aer.p20151021
 - [7] Hastie T. et al. The Elements of Statistical Learning: Data Mining, Inference and Prediction // The Mathematical Intelligencer. 2005. Vol. 27. No. 2. pp. 83-85. DOI: 10.1007/BF02985802
 - [8] Belloni A., Chernozhukov V., Hansen C. High-Dimensional Methods and Inference on Structural and Treatment Effects // Journal of Economic Perspectives. 2014. Vol. 28. No. 2. P. 29-50. DOI: 10.1257/jep.28.2.29
 - [9] Diebold F.X., Mariano R.S. Comparing Predictive Accuracy // Journal of Business & Economic Statistics. 2002. Vol. 20. No. 1. pp. 134-144. DOI: 10.1198/073500102753410444
 - [10] Imbens G.W., Rubin D.B. Causal Inference in Statistics, Social, and Biomedical Sciences. Cambridge: Cambridge University Press, 2015. 625 p.
 - [11] Shiller R.J. Irrational Exuberance: Revised and Expanded Third Edition. New York: Princeton University Press, 2016. 392 p.
 - [12] Hamilton J.D. Time Series Analysis. Princeton: Princeton University Press, 2020. 816 p.
 - [13] James G., Witten D., Hastie T., Tibshirani R. An Introduction to Statistical Learning: With Applications in R. 2nd ed. New York: Springer, 2021. 607 p.
 - [14] Wooldridge J.M. Introductory Econometrics: A Modern Approach. 7th ed. Boston: Cengage Learning, 2020. 878 p.
 - [15] Goodfellow I. et al. Deep Learning. Cambridge: MIT Press, 2016.
 - [16] Hyndman R.J., Athanasopoulos G. Forecasting: Principles and Practice. 3rd ed. Melbourne: OTexts, 2021. 442 p.
 - [17] Ashuri B., Lu J. Time Series Analysis of the ENR Construction Cost Index // Journal of Construction Engineering and Management. 2010. Vol. 136. No. 12. P. 1289-1299. DOI: 10.1061/(ASCE)CO.1943-7862.0000242