

Научно-исследовательский журнал «Экономический вестник / *Economic Bulletin*»  
<https://eb-journal.ru>  
2025, Том 4 № 2 / 2025, Vol. 4. Iss. 2 <https://eb-journal.ru/archives/category/publications>  
Научная статья / Original article  
УДК 330.4



<sup>1</sup> Пронин П.С.,  
<sup>1</sup> Российский экономический университет им. Г.В. Плеханова

### *Искусственный интеллект и конкуренция: предсказание потребительского спроса*

**Аннотация:** целью статьи является проверка гипотезы, что методы искусственного интеллекта и машинного обучения позволяют фирмам получить конкурентное преимущество через снижение неопределенности в предсказании потребительского спроса.

**Методы:** В статье сравниваются два подхода к оценке спроса: эконометрический подход на основе микрообоснованной и интерпретируемой модели BLP и статистический подход на основе методов машинного обучения. В частности, классическая модель сравнивается с линейными моделями с L1 и L2 регуляризацией, случайными лесами, градиентным бустингом, а также нейронной сетью.

**Результаты:** Сравнение моделей применительно к рынку автомобилей в США показало значительное преимущество моделей машинного обучения относительно модели BLP. Точность предсказания таких моделей превесило точность эконометрической модели в более чем десять раз.

**Выводы:** Результаты показывают, что применение методов машинного обучения в задаче предсказания потребительского спроса действительно способно радикально увеличить точность предсказания относительно стандартных моделей. Однако, в обмен на такую точность приходится жертвовать экономической интерпретацией параметров моделей.

**Ключевые слова:** рынок, экономическая конкуренция, оценка потребительского спроса, предсказание потребительского спроса, методы машинного обучения

**Для цитирования:** Пронин П.С. Искусственный интеллект и конкуренция: *предсказание* потребительского спроса // Экономический вестник. 2025. Том 4. № 2. С. 53 – 58.

Поступила в редакцию: 9 января 2025 г.; Одобрена после рецензирования: 6 марта 2025 г.; Принята к публикации: 28 апреля 2025 г.

<sup>1</sup> Pronin P.S.,  
<sup>1</sup> Plekhanov Russian University of Economics

### *Artificial intelligence and competition: prediction of consumer demand*

**Abstract:** the purpose of the article is to test the hypothesis that artificial intelligence and machine learning methods allow firms to gain a competitive advantage by reducing uncertainty in predicting consumer demand.

**Methods:** The article compares two approaches to demand estimation: an econometric approach based on a micro-founded and interpretable BLP model and a statistical approach based on machine learning methods. In particular, the classical model is compared with linear models with L1 and L2 regularization, random forests, gradient boosting, and a neural network.

**Findings:** Comparison of models applied to the US car market showed a significant advantage of machine learning models relative to the BLP model. The prediction accuracy of such models outweighed the accuracy of the econometric model by more than ten times.

**Conclusions:** The results show that the use of machine learning methods in the problem of predicting consumer demand can indeed radically increase the accuracy of prediction relative to standard models. However, in exchange for such accuracy, one has to sacrifice the economic interpretation of the model parameters.

**Keywords:** market, economic competition, consumer demand estimation, consumer demand forecasting, machine learning methods

**For citation:** Pronin P.S. Artificial intelligence and competition: prediction of consumer demand. Economic Bulletin. 2025. 4 (2). P. 53 – 58.

The article was submitted: January 9, 2025; Approved after reviewing: March 6, 2025; Accepted for publication: April 28, 2025.

### Введение

Появление новых технологий машинного обучения (МО) и искусственного интеллекта (ИИ) привело к изменению целого ряда бизнес-процессов. Технологии МО и ИИ позволяют обрабатывать огромные объемы неструктурированных данных, таких как тексты, изображения, звук или видео. Применение этих технологий также позволяет фирмам учесть больше информации в оптимизации своих процесс принятия решений, а также автоматизировать часть труда своих сотрудников.

Многие современные экономические исследования озабочены влиянием этих технологий на рыночную конкуренцию. Целый ряд теоретических моделей предполагает, что главный эффект технологий ИИ на деятельность фирм заключается в снижении неопределенности [4, 9, 10]. Действительно, современные методы машинного обучения позволяют лучше справляться с задачами предсказания и классификации. Особенно заметны улучшения в точности работы с неструктурированными данными. Однако в случае с структурированными данными эти методы не всегда оказываются полезными. Как известно, в ряде случаев простые модели способны быть гораздо более точными чем сложные методы машинного обучения. Более того, методы машинного обучения не способны учесть особенность экономического взаимодействия. В этой работе проверяется предположение, что методы ИИ и машинного обучения способны лучше справиться с задачей предсказания потребительского спроса, пожалуй, одной из главных задач, с которой сталкиваются современные фирмы, а также одной из самых хорошо изученных проблем с эконометрической точки зрения.

Современной фирме важно понимать какой может быть спрос на ее товар, поскольку это влияет как на ее ценообразование, так и на ее логистические решения. Также более точное понимание спроса позволяет фирмами планировать свои инвестиционные решения и поведение на рынке труда. Эти и другие причины во многом объясняют рост вакансий на специалистов по машинному обучению и искусственному интеллекту в последние годы [1,2,3]. В этой работе сравнивается два

ключевых подхода к анализу спроса: подход на основе машинного обучения и эконометрический подход оценки спроса на основе модели с случайными эффектами, коротко называемой BLP по инициалам ее авторов [5, 6]. Для сравнения моделей был использован набор данные по продажам автомобилям в США, использованный самими авторами модели BLP.

### Материалы и методы исследований

В этой работе сравнивается два подхода к оценке спроса – эконометрический подход и подход на основе машинного обучения. Рассмотрим детали этих подходов последовательно.

Эконометрическая модель. В начале рассмотрим классический подход к оценке спроса на основе модели BLP. Модель BLP имеет микроэкономическое основание и предполагает, что полезность покупателя  $i$  от товара  $j$  принимает вид  $u_{ij} = X_j\beta_i + \xi_j + e_{ij}$ , где  $X_j$  это вектор характеристик товара  $j$ ,  $\beta_i$  это вектор параметров, специфический для индивида  $i$ ,  $\xi_j$  это характеристика товара  $j$ , которую наблюдает покупатель (или произвольная функция от таких характеристик), но не наблюдает исследователь, а  $e_{ij}$  то случайная ошибка или шок предпочтений покупателя. Пусть  $\beta$  это математическое ожидание вектора  $\beta_i$ . Мы можем также представить полезность как  $u_{ij} = \delta_j + \mu_{ij} + e_{ij}$ , где  $\delta_j = X_j\beta + \xi_j$  это «средняя полезность» от товара  $j$ , а  $\mu_{ij}$  это отклонение от средней полезности для индивида  $i$ . В классической модели предполагается, что  $e_{ij}$  распределены согласно экстремальному распределению первого порядка и независимы между товарами и покупателями. Покупатели выбирают товар, который приносит им наибольшую полезность или выбирают не купить ни один товар (полезность в таком случае равна нулю), то есть вероятность что покупатель  $i$  выберет товар  $j$  принимает вид

$$p_j(\delta, \mu_i) = \frac{\exp(\delta_j + \mu_{ij})}{1 + \sum_{k=1}^J \exp(\delta_k + \mu_{ik})}$$

где  $J$  это количество товаров на рынке,  $\delta = (\delta_1, \dots, \delta_J)$  это вектор средних полезностей това-

ров, а  $\mu_i = (\mu_{i1}, \dots, \mu_{ij})$  это вектор отклонений. Предполагается, что отклонения  $\mu_i$  независимы между покупателями и распределены согласно функции распределения  $F_\mu$ . В таком случае рыночная доля товара  $j$  определяется как

$$s_j(\delta) = \int p_j(\delta, \mu) dF_\mu(\mu).$$

Пусть  $y = (y_1, \dots, y_j)$  это наблюдаемые рыночные доли товаров, тогда, как показали авторы модели BLP, приравнявая теоретические доли товаров к наблюдаемым в данных, мы можем найти вектор  $\delta^* = (\delta_1^*, \dots, \delta_j^*)$  как решение системы уравнений. Более того, при ряде условий решение будет единственным. В таком случае все, что остается сделать это использовать уравнение  $\delta_j^* = X_j \beta + \xi_j$ , чтобы получить оценку параметров  $\beta$ . В этом уравнении  $\xi_j$  играет роль ошибки, которая при этом связана с характеристиками товара  $X_j$ , поэтому использовать обучающую линейную регрессию нельзя из-за эндогенности. Использование методов инструментальных переменных позволяет корректно оценить  $\beta$ , а в качестве инструментов могут выступать характеристики других товаров. Существует много версий этой модели, которые ослабляют предположения и деляют модель более общей: так само распределение  $F_\mu$  может зависеть от дополнительных параметров, которые предстоит оценить, а также может зависеть от демографических или иных микроданных (таких как распределение дохода покупателей). Также для большей точности оценки некоторые модели моделируют и сторону предложения тоже. Текущая работа ограничивается оценкой классической модели, описанной выше. Для оценки модели был использован пакет `ruBLP`, который сочетает лучшие практики имплементации модели [8]. Модель BLP получила большое применение как в исследовании, так и на практике. Ее сильные стороны заключаются в оценке «глубинных» параметров, которые позволяют оценивать эффекты рыночных изменений: слияния фирм, введения новых налогов или субсидий.

Модели машинного обучения. Для сравнения с моделями машинного обучения эта работа оценивает ряд моделей, которые стали широко применяться на практике в последние годы. В частности, использовались следующие модели: линейные модели с регуляризацией L1 и L2, случайные леса, градиентный бустинг деревьями, а также нейронная сеть. Ниже приводится описание того, как работают эти модели. Все модели машинного обучения основаны на минимизации функционала

ошибки. Пусть,  $Q(w)$  это заданный функционал, где  $w$  это набор из параметров, которые используются для минимизации ошибки. Например, функционал со средней квадратичной ошибкой имеет вид  $Q(w) = \frac{1}{n} \sum_{i=1}^n (y_i - f(X_i, w))^2$ , где  $n$  это количество наблюдений,  $X_i$  это набор признаков, а  $f(X_i, w)$  это заданная функция, которая конвертирует признаки в предсказание для заданного вектора параметров  $w$ , например,  $f(X_i, w) = X_i^T w$  в случае линейной регрессии.

Модели с регуляризацией. Модели с регуляризацией вместо минимизации функционала ошибки  $Q(w)$  напрямую, минимизируют  $Q(w) + \alpha R(w)$ , где  $\alpha \geq 0$  это параметр регуляризации, а  $R(w)$  это дополнительный штраф. Например, L1-регуляризация имеет штраф  $R(w) = \sum_{i=1}^d |w_i|$ , где  $d$  это размерность вектора параметров, а L2-регуляризация имеет штраф  $R(w) = \sum_{i=1}^d w_i^2$ . Таким образом, модели с регуляризацией ищут модели, где векторы весов имеют «небольшие» значения.

Деревья решений и случайные леса. Модели на основе деревьев решений ищут способ разделения выборки путем построения бинарного дерева. Пусть  $I = \{1, \dots, n\}$  это множество индексов данных. В начале вся выборка разделяется на две части путем выбора переменной  $k$  и порога  $c$ , таких что  $S_l(k, c) = \{i: x_{ik} < c\}$  это индексы, попадающие в «левую» часть дерева, а  $S_r(k, c) = \{i: x_{ik} \geq c\}$  это индексы, попадающие в правую часть дерева. Далее рекурсивно каждое из множества  $S_l(k, c)$  и  $S_r(k, c)$  также делится внутри на две части, и так происходит до достижения критерия остановки. Поиск разделяющей переменной  $k$  и порога  $c$  на каждом этапе для подвыборке  $S$  происходит путем минимизации функционала ошибки, которые принимает следующий вид

$$Q(S, k, c) = L(S) - \frac{|S_l(k, c)|}{|S|} L(S_l(k, c)) - \frac{|S_r(k, c)|}{|S|} L(S_r(k, c)),$$

где  $|S|$  показывает размер (мощность) множества, а  $L(S)$  это средняя квадратичная ошибка по подвыборке  $S$ . Листья дерева, то есть финальные множества, полученные по завершению процедуры, используются для построения предсказаний. Если  $S$  это множество индексов в листе, то для задачи регрессии обычно используется простое среднее. Каждое отдельно взятое дерево имеет склонность к переобучению, то есть его результаты могут плохо обобщаться вне выборки. Метод случайных лесов позволяет уменьшить эту проблему. Идея метода состоит в том, чтобы вместо построения одного дерева строить «лес» из  $N$  де-

ревью. Каждое отдельно взятое дерево  $j$  строится на случайной подвыборке  $I_j \subset I$ , при этом построение случайной выборки происходит с возвращением. Также для построения дерева  $j$  вместо всех признаков используется также случайная выборка из признаков. Из-за случайного отбора признаков и случайного сэмпирования каждое дерево получается разным. В качестве предсказаний используются усредненные предсказания всех деревьев. Такой метод построения модели путем обучения базовых моделей на случайных подвыборках также называется бэггингом.

Бустинг деревьями. Еще одним популярным алгоритмом обучения моделей является бустинг. Идея бустинга также заключается в усреднении предсказаний моделей, но модели обучаются не на случайных подвыборках, а последовательно дополняя друг друга. Пусть  $f(\cdot)$  это некоторый метод предсказания, а  $Q(f, y) = \sum_{i=1}^n (y_i - f(x_i))^2$  это квадратичная ошибка на выборке, полученная для метода  $f$ . В бустинге первая модель ищется путем минимизации функционала  $Q(\cdot, y)$ . Вторая же модель ищется путем минимизации функционала  $Q(\cdot, e^{(1)})$ , где

$$e^{(1)} = (y_1 - f^{(1)}(x_1), \dots, y_n - f^{(1)}(x_n))$$

это ошибки, которые остались от первой модели. Третья модель минимизирует  $Q(\cdot, e^{(2)})$  и так далее. После построения  $N$  таких последовательных моделей, их предсказания усредняются  $f(x) = \frac{1}{N} \sum_{k=1}^N f^{(k)}(x)$ . Поиск моделей  $f^{(1)}, \dots, f^{(N)}$  на каждом этапе происходит не среди всех возможных моделей (что было бы невозможно), а среди заданного класса моделей. Популярным вариантом являются деревья решений. В таком случае метод называется бустингом деревьями. Метод градиентного бустинга является важным улучшением обычного бустинга. Вместо использования ошибок  $e^{(k)}$  на этапе  $k$  используются псевдоошибки  $r^{(k)} = (r_1^{(k)}, \dots, r_n^{(k)})$ , где ошибка для наблюдения  $i$  это

$$r_i^{(k)} = -\frac{\partial (y_i - f^{(k)}(x_i))^2}{\partial f^{(k)}(x_i)},$$

то есть вектор  $r^{(k)}$  это антиградиент функции потерь. Также вместо усреднения моделей используется их линейная комбинация  $f(x) = \sum_{k=1}^N \alpha_k f^{(k)}(x)$ , где коэффициент  $\alpha_k$  находится также путем минимизации ошибки. В этой работе была использована разновидность метода предложенная в [7],

которая добавляет к этой процедуре ряд небольших, но эмпирически значимых улучшений.

Нейронные сети. Модели с нейронными сетями – это очень гибкие модели, которые получили массу применений для решения множества задач. Пусть  $x$  это вектор признаков, которые получает модель на вход, тогда предсказания модели строятся как композиция ряда из функций следующего вида

$$f(x) = (h_N \circ \sigma_{N-1} \circ h_{N-1} \circ \dots \circ \sigma_1 \circ h_1)(x),$$

где трансформации  $h_k$  называется полносвязным скрытым слоем, а  $\sigma_k$  называется часто функцией активации. Каждый скрытый слой является аффинной трансформацией  $h_k(z) = W_k z + b_k$ , где  $W_k$  это матрица весов, а  $b_k$  это вектор констант. Функции активации же, как правило, имеют простой вид и применяются поэлементно. Популярным выбором является активация ReLU, которая принимает вид

$$\sigma(z) = (\max(0, z_1), \dots, \max(0, z_d)),$$

где  $z_i$  это  $i$ -тый компонент вектора  $z$ , а  $d$  это размерность вектора  $z$ . Обычно используется одна и та же функция активации во всей модели. Как видно из определения, модель может обладать чрезвычайно большим количеством параметров, которое считается как сумма из размерностей всех матриц  $W_k$  и векторов  $b_k$ . Параметры матриц  $W_k$  и векторов  $b_k$  находятся также путем минимизации квадратичной ошибки. Гибкость модели является также ее недостатком, поскольку найти «правильную» комбинацию размеров слоев может быть достаточно трудно.

Сравнение моделей. Модели машинного обучения обладают большим количеством параметров и поэтому склонны к переобучению, то есть к запоминанию данных. Такими моделями можно легко добиться идеального предсказания имеющихся данных, но очень неточных предсказаний на новых данных. Из-за этого вся выборка делится на три части: обучающую, валидационную и тестовую. На обучающей выборке подбираются базовые параметры моделей. На валидационной выборке подбираются гиперпараметры, такие как глубина деревьев или параметры регуляризации. Наконец, на тестовой выборке происходит итоговая оценка моделей. Поскольку в модели BLP нет гиперпараметров, которые бы требовали валидационной выборки, ее оценка производилась на обучающей и валидационной выборке. Для сравнения моделей использовалась среднеквадратичная ошибка, рассчитанная на обучающая и валидационной выборки, а также среднеквадратичная ошибка, рассчитанная на тестовой выборке.



Данные. В работе использовались данные, представленные изначально авторами модели BLP и приведенные в более удобный вид разработчиками пакетами *руBLP*. Данные содержат информацию по 20 рынкам автомобилей и содержат 2217 наблюдений. На каждом рынке присутствует несколько типов автомобилей, которые характеризуются (1) ценой (варежной в 10.000 долларах), (2) отношением лошадиных сил к весу автомоби-

ля, (3) системой кондиционирования (1, если система стандартная, и 0 иначе), (4) расходом бензина в ценовом выражении, а также (5) размером кузова. Зависимой переменной является рыночная доля типа автомобиля на заданном рынке, то есть отношение проданных машин к числу потенциальных покупателей. Описательные статистики по данными представлены в табл. 1.

Таблица 1

Описание данных.

Table 1

Data description.

Переменная	Среднее	Стандартное отклонение	Медиана	Уникальные значения
Доля рынка	0.001	0.001	0.001	2190
Цена	11.761	8.644	8.729	2146
Отношение лошадиных сил к весу	0.394	0.097	0.375	1890
Система кондиционирования	0.242	0.428	0.0	2
Расход в долларах на милю	2.085	0.698	2.01	681
Размер кузова	1.31	0.238	1.27	765

### Результаты и обсуждения

Результаты оценки моделей представлены в табл. 2. Все рассчитанные ошибки показывают среднеквадратичные отклонения настоящих рыночных долей от долей, полученных из оценки моделей. Для наглядности вместо долей были использованы проценты. Модели в таблице отсортированы по мере убывания ошибки на отложенной выборке. Как видно из таблицы, наилучшего результата удалось добиться, используя модель градиентного бустинга. Хотя модель на основе нейронных сетей и является потенциально более

гибкой, из-за сложности подбора оптимальных параметров ей не удалось добиться качества выше, чем у градиентного бустинга. Эконометрическая модель BLP с задачей предсказания справилась хуже всех остальных моделей. Во многом это связано с тем, что, в отличие от остальных моделей, BLP-модель была разработана не столько для предсказания новых рынков, сколько для изучения изменений в уже оцененных рынках. Тем не менее, в задачах предсказания модели машинного обучения обгоняют BLP в более чем десять раз.

Таблица 2

Результаты оценки моделей.

Table 2

Results of model evaluation.

Модель	Ошибка на обучающей выборке	Ошибка на отложенной выборке
Градиентный бустинг	0.0078	0.0045
Нейронная сеть	0.009	0.0048
Случайные леса	0.0063	0.0049
L1-регуляризация	0.0095	0.0054
L2-регуляризация	0.0095	0.0055
BLP-модель	0.0344	0.5823

### Выводы

Новые методы машинного обучения и ИИ действительно помогают фирмам снизить неопределенность в своих бизнес-процессах и обладают большим преимуществом в задачах предсказания по отношению к другим методам. В этой статье на

примере данных по автомобильным рынкам было показано, что новые методы также значительно превосходят эконометрические модели в задачах предсказания рыночного спроса. Таким образом, подтверждаются предположения, которые делают

экономисты в своих теоретических работах сегодня.

Однако, в отличие от эконометрических моделей, исключительно статистические модели машинного обучения не могут рассказать об объяснении природы своих предсказаний и предоставить эко-

номическую логику. В этом смысле методы машинного обучения позволяют снизить неопределенность в задачах предсказания, но в замен создают иного вида неопределенность – неопределенность в интерпретации моделей и в причинах таких предсказаний.

#### Список источников

1. Acemoglu D., Autor D., Hazell J., Restrepo P. Artificial intelligence and jobs: Evidence from online vacancies // *Journal of Labor Economics*. 2022. № 40. P. S293 – S340.
2. Alekseeva L., Azar J., Gine M., Samila S., Taska B. The demand for AI skills in the labor market // *Labour Economics*. 2021. № 71. C. 102002.
3. Babina T., Fedyk A., He A., Hodson J. Artificial intelligence, firm growth, and product innovation // *Journal of Financial Economics*. 2024. № 151. C. 103745.
4. Begenau J., Farboodi M., Veldkamp L. Big data in finance and the growth of large firms // *Journal of Monetary Economics*. 2018. № 97. P. 71 – 87.
5. Berry S. Estimating discrete-choice models of product differentiation // *The RAND Journal of Economics*. 1994. № 25.2. C. 242 – 262.
6. Berry S., Levinsohn J., Pakes A. Automobile Prices in Market Equilibrium // *Econometrica*. 1995. № 63.4. C. 841 – 890.
7. Chen T., Guestrin C. Xgboost: A scalable tree boosting system // *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. New York, NY, USA: Association for Computing Machinery, 2016. P. 785 – 794.
8. Conlon J., Gortmaker J. Best practices for differentiated products demand estimation with pyblp // *The RAND Journal of Economics*. 2020. № 51.4. P. 1108 – 1161.
9. Farboodi M., Veldkamp L. Data and markets // *Annual Review of Economics*. 2023. № 15. C. 23 – 40.
10. Gans J. Artificial intelligence adoption in a competitive market // *Economica*. 2023. № 90. C. 690 – 705.

#### References

1. Acemoglu D., Autor D., Hazell J., Restrepo P. Artificial intelligence and jobs: Evidence from online vacancies. *Journal of Labor Economics*. 2022. No. 40. P. S293 – S340.
2. Alekseeva L., Azar J., Gine M., Samila S., Taska B. The demand for AI skills in the labor market. *Labour Economics*. 2021. No. 71. P. 102002.
3. Babina T., Fedyk A., He A., Hodson J. Artificial intelligence, firm growth, and product innovation. *Journal of Financial Economics*. 2024. No. 151. P. 103745.
4. Begenau J., Farboodi M., Veldkamp L. Big data in finance and the growth of large firms. *Journal of Monetary Economics*. 2018. No. 97. P. 71 – 87.
5. Berry S. Estimating discrete-choice models of product differentiation. *The RAND Journal of Economics*. 1994. No. 25.2. P. 242 – 262.
6. Berry S., Levinsohn J., Pakes A. Automobile Prices in Market Equilibrium. *Econometrica*. 1995. No. 63.4. P. 841 – 890.
7. Chen T., Guestrin C. Xgboost: A scalable tree boosting system. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. New York, NY, USA: Association for Computing Machinery, 2016. P. 785 – 794.
8. Conlon J., Gortmaker J. Best practices for differentiated products demand estimation with pyblp. *The RAND Journal of Economics*. 2020. No. 51.4. P. 1108 – 1161.
9. Farboodi M., Veldkamp L. Data and markets. *Annual Review of Economics*. 2023. No. 15. P. 23 – 40.
10. Gans J. Artificial intelligence adoption in a competitive market. *Economica*. 2023. No. 90. P. 690 – 705.

#### Информация об авторе

Пронин П.С., аспирант, Российский экономический университет имени Г.В. Плеханова, г. Москва, Стремянный переулок, д. 36, [pronin.p@edu.rea.ru](mailto:pronin.p@edu.rea.ru)