



Внедрение технологий машинного обучения для улучшения системы управления ассортиментной матрицей компании

Гермашев К.Е., магистрант,

Финансовый университет при Правительстве РФ, Москва, Россия

Помулев А.А., к.э.н., доцент,

Финансовый университет при Правительстве РФ, Москва, Россия

Аннотация. В рамках настоящего исследования рассмотрена задача повышения эффективности управления ассортиментной матрицей торговой компании посредством внедрения инструментов интеллектуального анализа данных. Автором сформирована гипотеза о том, что прогнозирование спроса и оптимизация цен с применением современных методов машинного обучения способствуют максимизации объема продаж при одновременном соблюдении целевых ограничений по маржинальности.

Ключевые слова: машинное обучение, категорийный менеджмент, прогнозирование, прогнозирование объема продаж, автоматизация, автоматизация системы закупок.

Implementation of machine learning technologies to improve the company's assortment matrix management system

Germashev K.E., magister,

Financial University under the Government of the Russian Federation, Moscow, Russia

Pomulev A.A., PhD, Associate Professor,

Financial University under the Government of the Russian Federation, Moscow, Russia

Annotation. Within the framework of this study, the task of improving the efficiency of managing a company's assortment matrix through the introduction of data mining tools is considered. The author has formulated a hypothesis that demand

forecasting and price optimization using modern machine learning methods contribute to maximizing sales volume while simultaneously meeting target margin constraints.

Key words: machine learning, category management, forecasting, sales volume forecasting, automatization, procurement system automatization.

Введение. Несмотря на ощутимый прогресс в применении методов машинного обучения к задачам прогнозирования спроса и оптимизации цен, большинство решений по-прежнему основано на разрозненных моделях и экспертных оценках, что ограничивает потенциал повышения эффективности. В последнее время возрастающий интерес вызывает интеграция интеллектуальных систем, способных комплексно охватывать не только прогнозирование объема продаж, но и определение оптимальных ценовых сценариев в условиях конкурентной среды. В настоящей работе описан механизм управления ассортиментной матрицей на базе современных бустинговых алгоритмов, интегрированных по схеме Double Machine Learning (DML).

Актуальность настоящего исследования подтверждается потребностью бизнеса в формировании интеллектуализированных систем управления ассортиментом, которые позволяют не только оперативно реагировать на колебания спроса, но и оптимизировать процессы закупки, складирования и реализации продукции в соответствии с текущими рыночными условиями.

Цель исследования заключается в разработке и обосновании эффективности моделей оптимизации ассортиментной матрицы на базе методов интеллектуального управления, а также формировании практических рекомендаций по совершенствованию бизнес-процессов торговой компании.

Результаты исследования. В качестве эмпирической базы исследования использовался агрегированный массив данных о динамике продаж, включающий следующие параметры для каждого факта реализации товара: уникальный идентификатор артикула, дата и день недели продажи, принадлежность к группе и подгруппе, количество реализованных единиц, цена продажи, себестоимость, валовая прибыль, выручка, маржинальность, а также цены аналогичных товаров у трех ведущих конкурентов на соответствующий момент времени. Такая

структура данных обеспечивает исследование взаимосвязи между ценообразованием, конкурентной средой и результативностью товарных позиций в ассортименте.

Для последующего машинного анализа проведена комплексная предобработка данных, включавшая:

- исключение записей с отсутствующими или некорректными значениями ключевых экономических и идентификационных параметров, что обеспечило чистоту и репрезентативность выборки;
- фильтрацию выборки по критерию минимальной маржинальности (установлен порог 0,05), что позволило сфокусировать моделирование только на экономически целесообразных продажах;
- переименование всех столбцов в латинизированные идентификаторы без специальных символов для устранения потенциальных технических коллизий при обучении моделей;
- кодирование категориальных признаков («Артикул», «Группа товаров», «Подгруппа товаров») с использованием методов числовой трансформации (LabelEncoder), что необходимо для восприятия их алгоритмами машинного обучения.

Данный этап позволил подготовить качественный массив данных для постановки задачи регрессии: предсказания оптимального значения цены, максимизирующей объём продаж при заданных условиях.

Для достижения цели построения модели, которая способна предсказывать наиболее оптимальные сценарии по ценовому позиционированию товаров, принято решение использовать метод DML (Double Machine Learning) [8] что подразумевает построение двух моделей:

- построение модели цены — на факторах, исключаяющих обуславливающие факторы объема;
- построение модели объема — на факторах, исключаяющих обуславливающие факторы цены.

Данный подход обеспечивает построение двух взаимосвязанных моделей, которые объясняют ошибки друг друга. Полученная модель DML по своей сути является прокси-эластичностью, которая позволяет определять оптимальную цену по отношению к текущим ценам конкурентов, что обеспечивает максимизацию объема продаж в количественном выражении. Вторая часть модели DML обучается на данных, позволяющих предсказывать объем продаж в количественном выражении, вводным данным для которой является цена продажи товара.

Для решения поставленной задачи исходный датасет был разделен на две части для обучения двух моделей: модель определения оптимального уровня цены и модель прогнозирования объема продаж.

Первый набор данных для определения оптимального уровня цены включает в себя данные о продажах товара за период 2023-2024 гг. по дням, при этом данные о продажах не агрегированы в один день, а включают в себя все факты продаж. То есть для каждой пары артикул-дата может быть несколько записей, что объясняется продажами разным клиентам, либо разными менеджерами, при этом сами данные о менеджере и покупателе в массиве для обучения не содержатся, так как конечная цель определить оптимальную цену для всего рынка, а не для частного случая продажи. Такие данные создают лишний шум для модели и могут вносить искажения в качество ее работы.

Таким образом для первой модели для определения оптимального уровня цены сформирован датасет, который включает в себя информацию:

- артикул — уникальный идентификатор проданного товара;
- группа товаров — товарная группа каждого артикула;
- подгруппа товаров — подгруппа товарной группы каждого артикула;
- цена_пр, руб. — цена продажи в рублях
- цена_K1, руб. — цена конкурента 1 на аналогичный товар в момент продажи товара;
- цена_K2, руб. — цена конкурента 2 на аналогичный товар в момент продажи товара;

– цена_K3, руб. — цена конкурента 3 на аналогичный товар в момент продажи товара.

При этом предварительно данный массив данных сначала был агрегирован для каждого артикула по цене продажи и цене конкурентов, при условии, что данные отличаются не более 3% с целью определения общего объема продажи товара в определенных рыночных условиях (зависимость цены продажи и цены конкурентов). Затем агрегированный массив данных был разделен на четыре части (по квартилям) от объема продаж с целью ранжирования сделок по их эффективности для бизнеса, с целью дальнейшего отбора сделок, которые принесли наибольший объем продаж (четвертый квартиль).

Таким образом для обучения модели использовались данные о наиболее эффективных сделках для компании, соответствующие рыночным условиям.

Для решения поставленной задачи были выбраны три современных бустинговых алгоритма — LightGBM, CatBoost и XGBoost. Выбор данных моделей обусловлен следующими факторами:

– их высокая эффективность и точность при работе с табличными бизнес-данными, где большое значение имеют сложные взаимосвязи между многочисленными количественными и категориальными признаками;

– устойчивость бустинговых алгоритмов к выбросам и мультиколлинеарности;

– испытанная на практике способность данных инструментов выявлять сложные зависимости между конкурентным ценообразованием, себестоимостью и итоговыми объёмами продаж в условиях реального маркетинга;

– встроенные механизмы борьбы с переобучением благодаря использованию ансамблей деревьев решений [2]

Для сравнительной оценки эффективности моделей проведена их апробация на тестовой выборке, отделённой от данных для обучения. В табл. 1 представлены ключевые метрики качества обученных моделей.

Результаты оценки качества обученных моделей

Модель	MAE	RMSE	R2
LightGBM	0,72	1,63	0,49
CatBoost	0,64	1,42	0,57
XGBoost	0,48	1,23	0,62

Источник: составлено автором на основе результатов обучения моделей и оценки их качества

Представленные в табл. 1 метрики о качества обученных моделей характеризуют:

- средняя абсолютная ошибка (MAE) отражает среднее отклонение прогнозируемого значения объёма продаж от фактического, минимальное значение продемонстрировано моделью XGBoost (0,48);
- корень среднеквадратичной ошибки (RMSE) иллюстрирует общую точность прогноза, наименьший показатель достигнут в модели XGBoost (1,23);
- коэффициент детерминации (R^2) отражает долю объяснённой дисперсии и составляет 0,62 для XGBoost, что означает объяснение почти двух третей вариации исследуемой переменной.

Исходя из полученных результатов, модель XGBoost (XGBRegressor [9]) выбрана в качестве основной для дальнейшей интеграции в систему поддержки решений по управлению ассортиментной матрицей компании. Преимущество XGBoost заключается не только в показателях точности, но и в её масштабируемости в рамках дальнейшей оптимизации.

Таким образом, внедрение современных технологий машинного обучения, построенных на бустинговых алгоритмах, демонстрирует целесообразность и перспективность применения интеллектуальных методов для управления ассортиментом и ценообразованием в торговой компании. Используемый подход позволяет согласовывать стратегию формирования ассортимента с целями максимизации продаж и оптимизации прибыльности в условиях динамично меняющейся конкурентной среды.

После проведения подбора гиперпараметров алгоритма XGBoost (XGBRegressor) с помощью метода GridSearchCV были получены следующие наилучшие параметры модели:

- subsample: 1.0 — доля случайных выборок из обучающего набора данных, используемых для обучения каждого дерева;
- n_estimators: 400 — количество деревьев (итераций бустинга), которые будут построены;
- min_child_weight: 3 — минимальная сумма весов (или количество экземпляров);
- max_depth: 8 — максимальная глубина каждого дерева;
- learning_rate: 0.1 — шаг градиентного спуска, влияющий на вклад каждого дерева;
- gamma: 0.3 — минимальное значение уменьшения функции потерь, необходимое для дальнейшего разбиения узла;
- colsample_bytree: 0.8 — доля признаков, случайно выбираемых для построения каждого дерева.

Данные параметры обеспечили улучшение ключевых метрик на тестовой выборке. Сравнение метрик представлено в табл. 2.

Таблица 2

Сравнение метрик качества модели XGBRegressor до и после подбора параметров

Метрика	До подбора	После подбора
MAE	0,48	0,39
RMSE	1,23	1,04
R2	0,62	0,72

Источник: составлено автором на основе результатов обучения моделей и оценки их качества

Отраженные результаты свидетельствуют о положительной динамике качества прогноза после оптимизации параметров, однако абсолютное значение улучшения не является резким, что типично для задач прогнозирования на бизнес-данных с высокой степенью шума и отсутствием сверхинформативных

параметров. Автором в работе использован до настроенный вариант модели XGBoost с указанными параметрами.

Следующим этапом в работе необходимо обучить вторую модель, которая должна решать задачу прогнозирования дневного объема продаж (в натуральном выражении) по каждому конкретному артикулу на основании исторических данных о реализации товаров. Корректная модель прогноза необходима для повышения эффективности управления ассортиментной матрицей, формирования прогнозов закупки товаров и оптимизации складских запасов.

В качестве исходных данных для обучения модели был использован массив транзакционных данных о продажах, содержащий признаки: дату, день недели, уникальный артикул, наименование товарной и подгруппы, значения цены реализации, себестоимости, выручки, валовой прибыли, маржинальности. Каждая строка исходного датасета отражала отдельный факт продажи конкретного артикула в указанный день, при этом для одного артикула в один день могло быть зафиксировано несколько строк.

Для прогнозирования суточного объема продаж тестировалось несколько современных алгоритмов машинного обучения, каждый из которых обучался и тестировался на одном и том же наборе признаков:

- модели ансамблевого бустинга: XGBoost, LightGBM, CatBoost;
- классический ансамблевый метод: Случайный лес (Random Forest);
- линейная регрессия с регуляризацией: ElasticNet;
- метод ближайших соседей: KNN;
- простая нейронная сеть: MLPRegressor.

Наилучшие значения метрик прогнозирования показал алгоритм XGBoost, что видно по данным, отраженным в табл. 3.

В таблице представлены результаты сравнения различных моделей машинного обучения по трём основным метрикам качества: средней абсолютной ошибке (MAE), корню из средней квадратичной ошибки (RMSE) и коэффициенту детерминации (R^2).

Результаты оценки качества обученных моделей

Модель	MAE	RMSE	R ²
XGBoost	2,03	4,85	0,64
Random Forest	2,79	5,72	0,59
LightGBM	2,98	5,91	0,53
CatBoost	4,41	7,34	0,45
KNN	4,07	7,06	0,49
ElasticNet	5,79	9,86	0,38
MLPRegressor	6,61	10,11	0,32

Источник: составлено автором на основе результатов обучения моделей и оценки их качества

Анализируя представленные значения, можно отметить, что наилучшие показатели по всем трём метрикам продемонстрировала модель XGBoost (XGBRegressor): MAE = 2,03, RMSE = 4,85 и R² = 0,64. Данная модель реализует градиентный бустинг на деревьях решений, что обеспечивает высокую способность к аппроксимации сложных зависимостей в данных, а также эффективное использование регуляризации для предотвращения переобучения.

Таким образом, исходя из приведённых результатов анализа, для последующей работы по подбору оптимальных параметров и окончательной настройки модели был выбран алгоритм XGBoost — как показавший наилучшие значения всех используемых метрик качества и продемонстрировавший высокую способность к моделированию сложных взаимосвязей в данных.

Для повышения точности прогнозирования и усиления практической значимости модели на следующем этапе работы осуществлялась оптимизация её гиперпараметров с использованием комплексного поиска (RandomizedSearchCV). Параллельно проводилась перекрёстная проверка (кросс-валидация), что позволило получить объективную оценку способности алгоритма к обобщению и устойчивости к переобучению на различных подвыборках.

В результате настройки были определены следующие значения гиперпараметров, обеспечившие наилучший баланс между сложностью модели и её обобщающей способностью:

- subsample: 0.85 — используется 85% обучающих данных при построении каждого дерева, что снижает риск переобучения;
- n_estimators: 350 — количество построенных деревьев обеспечивает достаточную глубину ансамбля без избыточной сложности;
- min_child_weight: 4 — минимальное число экземпляров в листе уменьшает вероятность построения слишком мелких разбиений;
- max_depth: 7 — максимальная глубина дерева поддерживает оптимальный уровень детализации;
- learning_rate: 0.08 — пониженный шаг обучения способствует более устойчивой сходимости ансамбля;
- gamma: 0.2 — параметр регуляризации предотвращает негарантированное разбиение узлов;
- colsample_bytree: 0.75 — при построении каждого дерева используется случайная часть признаков для повышения общего разнообразия моделей.

Сравнительный анализ ключевых метрик на тестовой выборке приведён в табл. 4.

Таблица 4

Сравнение метрик качества модели XGBRegressor до и после подбора параметров

Метрика	До подбора	После подбора
MAE	2,03	1,79
RMSE	4,85	3,97
R2	0,64	0,74

Источник: составлено автором на основе результатов обучения моделей и оценки их качества

Как видно из представленных данных, оптимизация гиперпараметров позволила добиться значимого улучшения по всем критериям качества, хотя прирост по некоторым метрикам является умеренным. Это характерно для задач

бизнес-прогнозирования, отличающихся наличием зашумлённых данных, неявных закономерностей и ограниченного набора информативных признаков. При этом стабильность показателей до оптимизации свидетельствует о высокой базовой устойчивости XGBoost к характеристикам исходной выборки.

На основании полученных результатов для дальнейшей интеграции была выбрана до настроенная модель XGBoost с указанными выше параметрами. Такой подход позволяет реализовать эффективное, автоматизированное управление ассортиментной матрицей и поддерживать процесс принятия решений по ценообразованию, минимизируя затраты на ручную настройку модели по мере появления новых данных.

В целом проведённое исследование подтверждает актуальность применения бустинговых методов машинного обучения в торговой сфере для решения задач прогнозирования и оптимизации бизнес-процессов.

Проведённое обучение двух моделей для оптимизации ценового позиционирования и прогнозирования объёма продаж — формирует основу интеллектуальной системы поддержки принятия решений по управлению ассортиментной матрицей торговой компании. Для достижения максимального эффекта эти модели используются в связке, в едином цикле анализа и оптимизации.

Ключевая идея интеграции заключается в следующем: первая модель ценообразования определяет оптимальную цену на каждый товар, исходя из текущих рыночных условий и анализа конкурентных предложений, а вторая модель прогноза объёма продаж, в свою очередь, оценивает ожидаемое количество реализованных единиц по предложенной цене. Такой интеграционный подход позволяет получать прогнозируемый эффект от изменений в ценовой политике еще на этапе планирования продаж и складывания ассортиментной стратегии [7]. Наглядно схема работы моделей представлена на схеме (рис. 1).




Рис. 1 – Схема работы, предложенной DML модели

Источник: составлено автором на основе проведенного исследования

Технически цикл работы объединённых моделей реализуется через последовательную передачу входных и выходных данных:

1. для каждого товара с заданными характеристиками (группа, подгруппа, ценовые параметры конкурентов) модель XGBoost-ценообразования генерирует оптимальные ценовые рекомендации;
2. на следующем этапе, предложенные цены подаются на вход модели XGBoost-прогноза объёма продаж, где формируется предсказание по количеству реализуемых единиц по найденной оптимальной цене;
3. на основе полученного объёма продаж и ценовой рекомендации вычисляются все ключевые бизнес-показатели: выручка, валовая прибыль, уровень маржинальности, а также формируются итоговые предложения по заказу партий и корректировке складских запасов.

При необходимости, посредством перебора различных ценовых сценариев на выходе модели формируется набор альтернативных решений — таким образом обеспечивается возможность сценарного анализа и выбора наиболее выгодной стратегии с учётом бизнес-целей компании (максимизация прибыли, увеличение доли рынка, поддержание минимальных остатков и др.).

Особое значение приобретает итеративная схема работы модели: регулярно поступающие новые исторические данные о продажах актуализируют как ценовую, так и количественную модели, что позволяет оперативно корректировать ассортиментную матрицу в ответ на изменения рыночной конъюнктуры, предпочтений покупателей, сезонных трендов.

Практическая значимость внедрения интеллектуального управления ассортиментной матрицей должна оцениваться не только с позиций внедренных процедур и заложенных в систему принципов автоматизации, но — прежде всего — по фактическому эффекту, достигаемому в основных производственных метриках компании [4]. В данном подразделе проведено комплексное сравнение эффективности традиционного подхода категории управления и внедренной интеллектуальной системы, а также оценены ключевые экономические и операционные параметры, отражающие субстрат бизнес-преимущество от внедрения метода машинного обучения (ML) в качестве основного инструмента прогнозирования и планирования закупок.

В первой фазе апробации интеллектуальной системы на реальных данных исследуемой компании был проведён тестовый эксперимент: сравнивались прогнозные значения объёмов продаж по ассортименту запасных частей в период с 09.01.2025 по 31.03.2025, рассчитанные двумя способами — категорийным менеджером (по традиционной экспертной методике) и обученной моделью XGBoost, выступающей интеллектуальным ядром системы. Полученные результаты были сопоставлены с фактическими данными о реализованных товарах за тот же календарный промежуток.

Для визуализации результатов был построен график (рис. 2), на котором по оси X отображены даты реализации (дневные значения периода), а по оси Y — количество проданных товаров, выраженное в штуках за каждый день. Каждая из трех линий на графике отражает:

- линия 1 (зеленая) — фактическое значение продаж: объективная динамика продаж по всей исследуемой группе за рассматриваемый временной отрезок (факт)

- линия 2 (синяя) — прогноз менеджера: интегральная суммарная оценка выпуска продаж по дням, совершённая на основе субъективно-экспертной оценки, с учетом сезонных факторов, визуального анализа остатков, рыночной статистики и экспертных суждений категорийного менеджера;

– линия 3 (желтая) — прогноз интеллектуальной модели: расчетная траектория ожидаемых суточных продаж по результатам работы модели XGBoost, оптимизированной по результатам машинного обучения на генеральной совокупности истории продаж и конкуренции.




Рис. 2 – Сравнение фактических продаж, прогноза модели и прогноза менеджера по дням в период 09.01.2025–31.03.2025 в штуках

Источник: составлено автором на основе проведенного исследования

График демонстрирует, что обе прогнозные линии периодически отклоняются от реальных продаж — что естественно, учитывая рыночные флуктуации. Однако, оценка среднedayной точности (рассчитывалась как 1 – средняя абсолютная ошибка/факт продаж) свидетельствует о следующих результатах:

– средняя точность прогноза менеджера по дням составила 60%. Наиболее часто отмечались случаи недооценки спроса в периоды пиковых скачков (акционные периоды, внезапное повышение спроса), а также систематическая переоценка в низкосезонные окна;

– средняя точность модели (ML) оказалась выше — порядка 70%. Обработка модели более плавная и менее подвержена аномальным выбросам, однако и она иногда не «ловит» эффект внештатных событий (экстраординарное появление новых клиентов, неожиданные разовые закупки оптовиков и т.д.);

Таким образом, для компании становится очевидным — уже на суточном уровне интеллектуальная модель прогнозирования опережает менеджерский подход по точности оценки ожидаемых объёмов продажи запасных частей на 10 процентных пунктов. Это свидетельствует о том, что алгоритмическая система лучше справляется с агрегацией большого массива разнотипных факторов.

Выводы. В результате интеграции, предложенной DML модели в систему управления ассортиментной матрицей компании, формируется замкнутый контур интеллектуального управления ассортиментом и ценообразованием, обладающий следующими преимуществами:

- возможность адаптивного реагирования на изменения в конкурентной среде;
- автоматизация процесса формирования и актуализации ассортимента и ценовой политики;
- поддержка управленческих решений на основе данных (data-driven management);
- повышение точности прогнозирования ключевых бизнес-показателей: продаж, финансовых результатов, маржинальности;
- снижение влияния факторов человеческого субъективизма;
- повышение прозрачности, воспроизводимости и скорости бизнес-процессов [6].

Таким образом, созданная система, основанная на объединении двух моделей XGBoost, существенно расширяет возможности менеджмента компании в области стратегического управления ассортиментной матрицей и ценовой политикой, обеспечивает гибкость и эффективность в принятии решений, а также создает платформу для последующего развития интеллектуальных инструментов управления — в том числе оптимизации закупок, анализа оттока клиентов, интеграции с ERP и BI-системами компании.

Библиографический список:

1. Коротеев, М. В., Основы машинного обучения на Python : учебник / М.В. Коротеев. – Москва : КноРус, 2025. – 431 с. – ISBN 978-5-406-14728-3. [электронный ресурс] – Режим доступа. – URL: <https://book.ru/book/957785>
2. Кричевский, М. Л., Модели машинного обучения в менеджменте : учебное пособие / М. Л. Кричевский. – Москва : КноРус, 2024. – 197 с. – ISBN 978-5-406-13123-7. [электронный ресурс] – Режим доступа. – URL: <https://book.ru/book/954391>
3. Новые подходы к совершенствованию управления закупками в условиях цифровой трансформации : монография / И.П. Гладилина, С.А. Сергеева, М.Ю. Погудева [и др.] ; под общ. ред. И. П. Гладилиной. — Москва : Русайнс, 2024. – 107 с. – ISBN 978-5-466-07985-2. [электронный ресурс] – Режим доступа. – URL: <https://book.ru/book/955980>
4. Носова, С.С., Искусственный интеллект и экономика : учебник / С. С. Носова, А. Н. Норкина. – Москва : КноРус, 2024. – 399 с. – ISBN 978-5-406-12642-4. [электронный ресурс] – Режим доступа. – URL: <https://book.ru/book/951959>
5. Сергеева С.А. ИСКУССТВЕННЫЙ ИНТЕЛЛЕКТ В СФЕРЕ ЗАКУПОК: ВОЗМОЖНОСТИ И ПЕРСПЕКТИВЫ // Инновации и инвестиции. – 2022. – №12. [электронный ресурс] – Режим доступа. – URL: <https://cyberleninka.ru/article/n/iskusstvennyy-intellekt-v-sfere-zakupok-vozmozhnosti-i-perspektivy>
6. Эволюция закупок: зачем снабженцам искусственный интеллект // Forbes [электронный ресурс] – Режим доступа. – URL: <https://www.forbes.ru/partnerskie-materialy/413457-evolyuciya-zakupok-zachem-snabzhencam-iskusstvennyy-intellekt>
7. AI and Category Management: Impact & What You Need to Know // Cantactix [электронный ресурс] – Режим доступа. – URL: <https://cantactix.com/ai-and-catman/>
8. Double Machine Learning // DoubleML [электронный ресурс] – Режим доступа. – URL: <https://docs.doubleml.org/stable/guide/models.html>

9. XGBoost Documentation // DMLC XGBoost [электронный ресурс] – Режим доступа. – URL: https://xgboost.readthedocs.io/en/release_3.0.0/

References:

1. Koroteev, M.V., Fundamentals of machine learning in Python: textbook / M.V. Koroteev. – Moscow : KnoRus, 2025. – 431 p. – ISBN 978-5-406-14728-3. [electronic resource] – Access mode. – URL: <https://book.ru/book/957785>

2. Krichevsky, M.L., Machine learning models in management : a textbook / M. L. Krichevsky. – Moscow : KnoRus, 2024. – 197 p. – ISBN 978-5-406-13123-7. [electronic resource] – Access mode. – URL: <https://book.ru/book/954391>

3. New approaches to improving procurement management in the context of digital transformation : a monograph / I. P. Gladilina, S. A. Sergeeva, M. Y. Pogudaeva [et al.]; under the general editorship of I. P. Gladilina. – Moscow : Rusains, 2024. – 107 p. – ISBN 978-5-466-07985-2. [electronic resource] – Access mode. – URL: <https://book.ru/book/955980>

4. Nosova, S.S., Artificial intelligence and economics : textbook / S.S. Nosova, A.N. Norkina. – Moscow : KnoRus, 2024. – 399 p. – ISBN 978-5-406-12642-4. [electronic resource] – Access mode. – URL: <https://book.ru/book/951959>

5. Sergeeva S.A. ARTIFICIAL INTELLIGENCE IN THE FIELD OF PROCUREMENT: OPPORTUNITIES AND PROSPECTS // Innovations and investments. – 2022. – № 12. [electronic resource] – Access mode. – URL: <https://cyberleninka.ru/article/n/iskusstvennyy-intellekt-v-sfere-zakupok-vozmozhnosti-i-perspektivy>

6. The evolution of procurement: why suppliers need artificial intelligence // Forbes [electronic resource] – Access mode. – URL: <https://www.forbes.ru/partnerskie-materialy/413457-evolyuciya-zakupok-zachem-snabzhencam-iskusstvennyy-intellekt>

7. AI and Category Management: Impact & What You Need to Know // Cantactix [electronic resource] – Access mode. – URL: <https://cantactix.com/ai-and-catman/>

8. Double Machine Learning // DoubleML [electronic resource] – Access mode. – URL: <https://docs.doubleml.org/stable/guide/models.html>

9. XGBoost Documentation // DMLC XGBoost [electronic resource] – Access mode. – URL: https://xgboost.readthedocs.io/en/release_3.0.0/

Для цитирования: Гермашев К.Е., Помулев А.А., Внедрение технологий машинного обучения для улучшения системы управления ассортиментной матрицей компании / Российский экономический интернет-журнал. – 2024. – № 2. URL:

© Гермашев К.Е., Помулев А.А., Российский экономический интернет-журнал 2025, № 2