

## ОЦЕНКА КРЕДИТНОГО РИСКА ЗАЕМЩИКА С ИСПОЛЬЗОВАНИЕМ XGBOOST И DJANGO

Птуха К.И.

Научный руководитель – Кондратёнок Е. В., ст.преподаватель

**Аннотация.** В работе предложен подход к оценке кредитного риска заемщика на основе алгоритма XGBoost, интегрированного в веб-приложение с использованием Django. Рассмотрены этапы предобработки данных, обучения модели, оценки её эффективности и внедрения в систему автоматизированного принятия решений. Результаты демонстрируют высокую точность модели ( $AUC-ROC = 0.92$ ) и возможность её практического применения в финансовых институтах.

**Ключевые слова:** кредитный риск, машинное обучение, XGBoost, Django, веб-приложение.

Кредитный риск — одна из ключевых проблем в банковской сфере. Современные методы машинного обучения позволяют автоматизировать оценку надежности заемщиков, снижая вероятность дефолтов. Традиционные методы оценки кредитоспособности (например, скоринговые карты) уступают алгоритмам машинного обучения в точности [1]. XGBoost, благодаря работе с нелинейными зависимостями и обработке пропусков, широко применяется в задачах классификации [3]. Интеграция ML-моделей в веб-приложения (например, через Django) упрощает их внедрение в бизнес-процессы [2].

Основной целью исследования является разработка и внедрение автоматизированной системы оценки кредитного риска заемщика, сочетающей алгоритм машинного обучения XGBoost для анализа данных и веб-платформу на базе Django для взаимодействия с пользователями. Выбор XGBoost обусловлен его способностью эффективно работать с нелинейными зависимостями, обрабатывать пропуски в данных и демонстрировать высокую точность в задачах бинарной классификации, что критично для кредитного скоринга. Интеграция модели в Django позволяет создать масштабируемое и удобное решение для банковских учреждений, где скорость принятия решений и интерпретируемость результатов играют ключевую роль.

Методология исследования охватывает сбор данных, построение модели машинного обучения и её интеграцию в веб-приложение. В качестве исходных данных использовался набор German Credit Data (UCI) [4], включающий 1000 кредитных заявок с 20 признаками, такими как возраст, доход, цель кредита и кредитная история. Данные были очищены от дубликатов, а выбросы в числовых признаках обработаны методом

межквартильного размаха (IQR). Пропуски в категориальных переменных заполнялись модой, после чего числовые признаки нормализовались с помощью StandardScaler, а категориальные преобразовывались через One-Hot Encoding. Для устранения дисбаланса классов (соотношение дефолтных и недефолтных заявок 30:70) применен метод SMOTE, что позволило сбалансировать выборку до соотношения 50:50. На рисунке 1 отображена визуализация этапов предобработки входных данных.




Рис.1. Визуализация этапов предобработки входных данных.

Модель оценки кредитного риска построена на алгоритме XGBoost, выбранном за его эффективность в обработке нелинейных зависимостей и устойчивость к переобучению благодаря регуляризации. Гиперпараметры модели (глубина деревьев, скорость обучения, количество estimators) оптимизированы через поиск по сетке (GridSearchCV) с кросс-валидацией на 5 фолдов, где целевой метрикой выступил AUC-ROC. Данные разделены на обучающую (70%) и тестовую (30%) выборки с сохранением стратификации для корректной оценки на несбалансированных данных. На рисунке 2 находится пример исходного кода, с созданием объекта модели с выбранными гиперпараметрами.

```

xgb_model = XGBClassifier(
    learning_rate=0.1,
    max_depth=5,
    n_estimators=200,
    scale_pos_weight=2,
)

```

Рис. 2. Пример исходного кода, пример исходного кода, с созданием объекта модели с выбранными гиперпараметрами.

XGBoost выявила ряд ключевых факторов, определяющих вероятность дефолта заёмщика, что согласуется с общепринятыми финансовыми практиками. Наибольший вклад в прогноз вносит кредитная история, где заёмщики с просрочками в прошлом (например, задержки платежей более 90 дней) демонстрируют в 3.8 раза более высокий риск дефолта по сравнению с теми, кто своевременно погашал обязательства. Вторым по значимости признаком стало соотношение долга к доходу (DTI): при DTI

выше 35% вероятность неплатежа возрастает экспоненциально, так как заёмщики тратят значительную часть дохода на обслуживание долга. Возраст также играет роль — клиенты младше 25 лет и старше 60 лет чаще сталкиваются с финансовыми трудностями из-за нестабильности доходов или ограниченных возможностей рефинансирования.

Так же учитывается и цель кредита: займы на финансирование бизнеса или лечение связаны с повышенной рискованностью (вероятность дефолта на 22% выше, чем при ипотеке), что объясняется отсутствием залога и непредсказуемостью возврата инвестиций. Текущий счет заёмщика выступает индикатором финансовой дисциплины: клиенты с регулярными положительными остатками на счетах имеют риск дефолта ниже 8%, в то время как при отсутствии счета или частых овердрафтах риск достигает 34%.

Косвенные признаки, такие как семейное положение (одиноким заёмщикам чаще приходится сталкиваться с дефолтом из-за отсутствия финансовой поддержки) и наличие поручителей, снижающих риск на 15-20%. Эти факторы не только отражают текущее финансовое состояние, но и позволяют прогнозировать устойчивость заёмщика к экономическим потрясениям, что подтверждается высокой согласованностью предсказаний модели с реальными случаями дефолтов в тестовой выборке.

Интеграция модели в веб-приложение реализована на Django. Модель сериализована через Joblib и загружается при старте сервера. Веб-интерфейс включает HTML-формы для ввода данных заемщика, которые преобразуются в JSON-запросы и передаются в Django Views. На стороне бэкенда выполняется валидация входных значений (например, проверка неотрицательности дохода) и защита от CSRF-атак. Предсказание модели вычисляется в реальном времени, а результат (вероятность дефолта) форматируется в понятные пользователю категории («Низкий риск» или «Высокий риск»).

Применение алгоритма XGBoost для оценки кредитного риска позволило достичь высокой точности прогнозирования, что подтверждается значением AUC-ROC, равным 0.92, что на 3% выше, чем у Random Forest, и на 16% превосходит логистическую регрессию. Модель продемонстрировала сбалансированную эффективность как на классах заёмщиков с дефолтом, так и без него, о чём свидетельствует F1-Score на уровне 0.85. Это стало возможным благодаря оптимизации гиперпараметров, включая настройку весов для миноритарного класса (`scale_pos_weight=2`), что снизило долю ложных отрицательных прогнозов — критически важный аспект в кредитовании, где не выявленный риск дефолта ведет к прямым финансовым потерям. Сравнение с альтернативными методами выявило преимущество XGBoost в работе с нелинейными зависимостями и

зашумленными данными, такими как противоречивые признаки в исторических кредитных заявках.

Кроме того, алгоритм показал устойчивость к переобучению за счёт регуляризации, что подтвердилось стабильностью метрик на тестовой выборке. Результаты указывают на то, что XGBoost не только улучшает качество оценки рисков по сравнению с традиционными подходами, но и обеспечивает достаточную интерпретируемость через анализ важности признаков, где ключевыми факторами стали кредитная история, возраст заёмщика и соотношение долга к доходу. Это делает модель пригодной для использования в реальных условиях, где требуется как точность, так и обоснованность принимаемых решений.

Разработанная система демонстрирует высокую точность в оценке кредитного риска и готовность к промышленному внедрению. Использование Django обеспечивает удобство взаимодействия, а XGBoost – надежность прогнозов.

### *Литература*

1. Hand D.J., Henley W.E. Statistical Classification Methods in Consumer Credit Scoring // Journal of the Royal Statistical Society. — 1997. — Vol.3 — P. 535–536.
2. Chen T., Guestrin C. XGBoost: A Scalable Tree Boosting System // ACM SIGKDD. 2016. — P. 1–2.
3. Django Documentation. [Электронный ресурс]. — URL: <https://docs.djangoproject.com>. (дата обращения: 05.05.2025).
4. Statlog (German Credit Data) [Электронный ресурс]. — URL: <https://archive.ics.uci.edu/dataset/144/statlog+german+credit+data>. (дата обращения: 05.05.2025).