ӘЛЕУМЕТТІК-ЭКОНОМИКАЛЫҚ ЖӘНЕ ҚҰҚЫҚ ҒЫЛЫМДАРЫ
СОЦИАЛЬНО-ЭКОНОМИЧЕСКИЕ И ЮРИДИЧЕСКИЕ НАУКИ
SOCIO-ECONOMIC AND LEGAL SCIENCES

CENTRAL ASIAN SCIENTIFIC JOURNAL
ISSN 3135-3061
2026. №4 (32), Том 2. С. 55–60
DOI: https://doi.org/10.5281/zenodo.23996807
Сайт журнала: https://cajournal.kz

УДК 339

МЕТОДИКА ОЦЕНКИ ЭФФЕКТИВНОСТИ ИНТЕЛЛЕКТУАЛЬНОЙ МАРШРУТИЗАЦИИ ПРИ ПЛАНОВОЙ ДОСТАВКЕ ТОВАРОВ ДИСТРИБЬЮТОРСКИМИ ПРЕДПРИЯТИЯМИ КАЗАХСТАНА

С.С. Сагалиев
КазНУ имени аль-Фараби

Сагалиев Саур Советович — магистрант, КазНУ имени аль-Фараби.
Научный руководитель: д.э.н, проф. - Сансызбаева Г.Н.

© С.С. Сагалиев, 2026

Аннотация: В данном исследовании предлагается методика сравнительной оценки ручного, алгоритмического и интеллектуального планирования маршрутов при регулярной доставке товаров в торговые точки, определяются требования к сопоставимости сценариев, составу исходных данных и ограничениям транспортной задачи. В статье рассмотрена система показателей эффективности, порядок расчёта экономического результата и протокол проверки добавочного эффекта прогнозных моделей машинного обучения, учтены отраслевые особенности плановой дистрибуции, включая фиксированные окна приёмки, повторяемость адресов и связь транспортных операций с графиками отгрузки.

Ключевые слова: логистика последней мили, плановая дистрибуция, маршрутизация, VRPTW, машинное обучение, оценка эффективности, TMS, транспортные затраты.

Введение

Регулярная доставка продукции со склада в торговые точки отличается от экспресс-доставки конечным покупателям. Маршруты повторяются, клиенты имеют устойчивые графики приёмки, а одна машина обслуживает множество точек за рейс. В этих условиях результат планирования определяется не только километражем, но и соблюдением окон доставки, доступностью автомобилей и согласованностью со складской отгрузкой.

Автоматизация расчёта маршрутов часто рассматривается как доказательство эффективности искусственного интеллекта. Однако математический алгоритм маршрутизации и модель машинного обучения решают разные задачи: первый ищет допустимый маршрут по заданным параметрам, вторая может прогнозировать параметры движения и обслуживания. Поэтому изменение показателей после внедрения TMS ещё не доказывает самостоятельного вклада искусственного интеллекта [1, 2].

Цель исследования — разработать воспроизводимую методику оценки эффективности интеллектуальной маршрутизации при регулярной доставке товаров дистрибьюторскими предприятиями Казахстана. Задачи: определить сопоставимые сценарии планирования; задать единые ограничения; выбрать KPI и способы их расчёта; сформулировать порядок проверки результатов и экономического эффекта.

Объект исследования и ограничения плановой доставки

Объектом исследования являются предприятия хлебобулочной промышленности, предметом - процесс распределения заказов между автомобилями и построения маршрутов

от распределительного склада до торговых точек. Единицей наблюдения предлагается считать доставочный день, а дополнительными единицами — маршрут, автомобиль и заказ. Планируемый рейс должен учитывать массу и объём груза, допустимую продолжительность смены, доступность автомобиля, адреса клиентов, окна приёмки и нормативное время обслуживания.

Для предприятий хлебобулочной промышленности перечень ограничений дополняется временем готовности продукции и последовательностью складской комплектации. При частой ежедневной доставке особенно важно учитывать особенности разгрузки каждой торговой точки и недопустимость опозданий на ранних рейсах.

Исследовательское допущение: все три сравниваемых подхода получают одинаковые заказы, один и тот же парк машин и идентичные ограничения. Данные о фактическом движении и времени обслуживания используются только в предусмотренных протоколом этапах. Без соблюдения этого условия изменение KPI может объясняться не качеством маршрутизации, а различиями в нагрузке.

Три сценария планирования и их различия

Для определения добавочного эффекта интеллектуального компонента предлагается сравнить три сценария.

Таблица 1 — Сценарии сравнительного исследования

Сценарий	**Принцип формирования маршрутов**	**Использование данных**
A — ручной	Маршруты формирует логист по действующей практике	Текущие справочники, опыт сотрудника
B — алгоритмический	VRP/VRPTW с заданными нормативами времени	Те же заказы и ограничения, фиксированные параметры
C — интеллектуальный	Тот же оптимизатор, но с прогнозными параметрами	Исторические данные для оценки времени движения/разгрузки

Сценарий B позволяет оценить эффект перехода от ручной работы к математической оптимизации. Разница между B и C показывает возможный добавочный эффект прогнозных моделей ИИ. Для корректности сравнения в сценариях B и C рекомендуется использовать один оптимизатор, одинаковую целевую функцию и одни ограничения; меняться должны только прогнозируемые входные параметры.

Модель C может оценивать ожидаемое время прибытия с помощью регрессионных алгоритмов на признаках «день недели», «время отправления», «участок маршрута», «история движения» и «тип торговой точки». Классические алгоритмы VRPTW остаются механизмом расчёта последовательности посещений. Это предотвращает ошибочное отождествление любой автоматизации с ИИ [2, 3].

Исходные данные и процедура исследования

Для апробации необходимы: реестр заказов (дата, идентификатор, адрес, масса и объём); проверенные координаты и окна приёмки торговых точек; грузоподъёмность, вместимость и доступность автомобилей; плановое и фактическое время выезда, прибытия, разгрузки и возвращения; GPS-пробег; затраты на транспорт, логистов, ПО и внедрение. Каждая запись связывается с датой, рейсом и заказом. Персональные сведения обезличиваются.

Протокол включает пять шагов. Сначала проводится очистка геоданных: устранение дублей, проверка координат и исключение явно ошибочных отметок времени. Затем формируется набор сопоставимых доставочных дней, отражающих разные уровни загрузки. Третий шаг — расчёт маршрутов по сценариям A, B и C при одинаковых заявках и парке. Четвёртый — проверка ограничений, оценка KPI и ошибок прогнозирования. Пятый — экономическая интерпретация, проверка устойчивости выводов по разным дням и документирование причин отклонений.

Для обучения модели машинного обучения исторические данные необходимо делить по времени: более ранние наблюдения — на обучение, последующие — на проверку. Нельзя

использовать фактические сведения о тестовом дне, которые не были доступны в момент планирования. Иначе возникает утечка данных и завышение заявленной точности.

Желательно применять парное сравнение по одинаковым датам и заказам. Если сценарии B и C рассчитываются ретроспективно, необходимо отдельно различать расчётные показатели маршрутов и показатели, подтверждённые фактическим выполнением; расчётная своевременность не должна представляться как измеренная.

Система показателей и расчёт эффекта

Таблица 2 — Основные показатели оценки эффективности

Показатель	Единица	Способ оценки
Пробег на доставку	км/заказ	Суммарный пробег / число выполненных доставок
Время планирования	мин/день	От загрузки заказов до утверждения маршрутов
Своевременность (OTD)	%	Доставки в окне / все выполненные доставки × 100
Продолжительность рейса	ч/рейс	От выезда со склада до завершения рейса
Стоимость доставки	тенге/заказ	Сопоставимые затраты / число доставок
Нарушения ограничений	ед./день	Нарушения окон, загрузки, длительности смены
Ошибка прогноза времени	мин	Средняя абсолютная ошибка прогноза ETA

Для оценки сокращения показателя, который следует минимизировать (например, километраж, длительность планирования или затраты), применяется стандартная формула относительного изменения:

Для всех KPI берутся данные одного периода и одинакового перечня заявок; расчётные значения маршрутов нельзя представлять как подтверждённые фактическим выполнением. В таблице 2 приведены показатели, необходимые для количественного сравнения.

$\Delta X = (X_0 - X_1) / X_0 \times 100\%$, где X_0 — значение KPI в базовом сценарии, X_1 — значение того же KPI в сравниваемом сценарии; единицы измерения должны совпадать. Источник данных: GPS-треки для пробега, журнал формирования маршрутов для времени планирования, финансовый учёт для затрат. При $X_0 = 0$ показатель не рассчитывается. Пример (условный): сокращение пробега с 1200 до 1020 км составляет (1200 − 1020) / 1200 × 100% = 15%. Для OTD изменение в первую очередь показывают в процентных пунктах.

Эффект автоматизации и добавочный эффект интеллектуальной модели следует рассчитывать раздельно:

$E_{авт} = KPI(A) - KPI(B)$; $E_{ИИ} = KPI(B) - KPI(C)$.

KPI(A), KPI(B), KPI(C) — значения одного и того же показателя соответственно при ручном, алгоритмическом и интеллектуальном планировании. $E_{авт}$ и $E_{ИИ}$ измеряются в тех же единицах, что и исходный KPI: для пробега — в километрах, для затрат — в тенге. Вычитание в указанном порядке применимо только к показателям, которые следует минимизировать; для своевременности доставки порядок вычитания меняется. Пример (условный): пробег A = 1200 км, B = 1020 км, C = 960 км; эффект автоматизации = 180 км, дополнительный эффект ИИ = 60 км (5,88% от B). Эти разницы отражают сравнение сценариев, но без контролируемого эксперимента не доказывают причинного эффекта ИИ.

Своевременность доставки (On-Time Delivery, OTD) показывает долю выполненных заказов, прибывших в согласованные окна приёмки. В методике момент выполнения условия «вовремя» фиксируется как прибытие к торговой точке в её временное окно:

$OTD = N_{вовремя} / N_{всего} \times 100\%$.

где $N_{вовремя}$ — число выполненных доставок с фактическим временем прибытия в согласованном интервале, $N_{всего}$ — общее число выполненных доставок за тот же период.

Данные: временное окно заказа и фактическая отметка прибытия из TMS/GPS/приложения водителя. Пример (условный): 279 своевременных доставок из 300 дают OTD = 93%. Рост OTD с 88% до 93% составляет 5 процентных пунктов.

Удельная стоимость доставки характеризует сумму сопоставимых транспортных и цифровых затрат в расчёте на одну выполненную доставку:

Сд = (Транспорт + СПО + Синтеграция_период) / Nдоставок.

где Транспорт — топливо, оплата труда водителей и иные затраты эксплуатации за период; СПО — лицензии и сопровождение TMS за тот же период; Синтеграция_период — распределённая на период доля разовых затрат на внедрение; Nдоставок — число выполненных доставок в данном периоде. Источники: бухгалтерский учёт, путевые листы и ведомости ГСМ, табели/зарплатные начисления, договоры на ПО и акты интеграции. Расходы на планирование логистом необходимо включать в соответствующую категорию для всех сценариев. Нельзя дважды учитывать одни и те же расходы. Пример (условный): (3 000 000 + 200 000 + 100 000) / 6000 = 550 тенге за доставку. Даже снижение пробега не гарантирует снижения данной суммы из-за дополнительных расходов на ИТ.

Точность модели, прогнозирующей длительность движения, разгрузки либо ETA, предлагается проверять через среднюю абсолютную ошибку (MAE), стандартную метрику регрессии:

$$MAE = (1/n) \times \Sigma |t_{факт,i} - t_{прогноз,i}|.$$

где n — число прогнозов; $t_{факт,i}$ — фактическое значение времени для i-го наблюдения; $t_{прогноз,i}$ — значение, предсказанное моделью до начала соответствующего этапа; |...| — абсолютная величина ошибки. Оба времени измеряются одинаково, например в минутах. Источники: прогнозная выгрузка модели и фактические отметки TMS/GPS. Пример (условный): при абсолютных ошибках 3, 2, 5 и 2 мин MAE = (3 + 2 + 5 + 2) / 4 = 3 мин. Для оценки качества модели показателю нужна проверка на данных, не участвовавших в её обучении.

Снижение MAE само по себе не доказывает экономический эффект: необходимо проверить, меняет ли более точный прогноз итоговые маршруты и операционные KPI. Значения для сценариев B и C сопоставляются на одинаковых тестовых днях с общим оптимизатором и ограничениями. Если C не даёт устойчивого улучшения относительно B, дополнительные затраты на ИИ могут оказаться нецелесообразными. Формулы относительного изменения, OTD и MAE — общепринятые способы расчёта показателей; авторский вклад состоит в схеме их совместного использования для сопоставления трёх сценариев, а не в создании новых математических выражений.

Условия интерпретации результатов и ограничения методики

Для оценки научной состоятельности результатов предлагается заранее зафиксировать основные показатели, допустимые нарушения ограничений и период наблюдения. Итог рекомендуется представлять по каждой дате и в сводной таблице, указывая медианные значения, разброс и число наблюдений. При наличии достаточного числа сопоставимых дней возможно проверить статистическую значимость парных различий.

Разделение трёх сценариев позволяет ответить на два разных вопроса: помогает ли математическая оптимизация по сравнению с действующей практикой и даёт ли машинное обучение измеримое улучшение сверх алгоритмического решения. При таком подходе отрицательный или нулевой результат сценария C также является содержательным научным выводом.

Ограничения методики связаны с полнотой GPS-истории, точностью координат, качеством фиксации времени разгрузки, непредвиденными дорожными событиями и различиями между расчётными и фактическими маршрутами. Влияние управленческих корректировок логиста следует фиксировать отдельно. Результаты одного предприятия не следует автоматически переносить на все компании Казахстана.

© Central Asian Scientific Journal, 2026

Практические рекомендации для дистрибьюторских предприятий

На первом этапе предприятию целесообразно провести аудит адресов, временных окон и фактической загруженности автомобилей. Затем рекомендуется наладить передачу заказов из учётной системы в TMS и запустить базовый алгоритм VRPTW. После накопления достоверной истории рейсов можно разработать прогнозную модель времени движения и разгрузки. Только после сравнения сценариев B и C следует принимать решение о масштабировании интеллектуального модуля.

Таблица 3 — Этапы обоснования внедрения интеллектуальной маршрутизации

Этап	Проверяемое условие	Критерий перехода
1. Подготовка данных	Проверены адреса, окна, автомобили	Данные пригодны для расчёта маршрутов
2. Базовая автоматизация	Сравнены A и B	Оценён эффект алгоритмического планирования
3. Прогнозная модель	Измерена точность прогноза на новых данных	Нет утечки данных, ошибка приемлема
4. Пилот ИИ	Сравнены B и C на одинаковых днях	Подтверждён добавочный операционный эффект
5. Экономическая оценка	Учтены затраты на внедрение и поддержку	Подтверждена целесообразность масштабирования

Для хлебобулочной дистрибуции особое значение имеет объединение в одной модели времени готовности продукции, слотов отгрузки и времени приёмки торговых точек. Внедрение следует начинать с ограниченного числа маршрутов, сохраняя возможность вмешательства логиста и регистрации причин ручных изменений.

Результаты исследования

Результатом настоящей работы является методика сравнения трёх подходов к планированию маршрутов при одинаковой транспортной задаче. Предложены единые требования к данным и ограничениям, набор операционных и финансовых KPI, способы расчёта эффектов автоматизации и машинного обучения, а также этапы внедрения интеллектуального модуля.

Отличие предложенной методики состоит в явном выделении сценария базовой математической оптимизации как обязательного контрольного варианта. Это позволяет не приписывать искусственному интеллекту результаты, которые могут быть достигнуты обычным алгоритмическим планированием. Эмпирическая апробация методики является следующим этапом исследования; числовые значения экономии в статье не приводятся ввиду отсутствия подтверждённого набора исходных данных.

Заключение

При плановой доставке товаров эффективность маршрутизации определяется сочетанием пробега, ограничений грузоподъёмности, графиков приёмки и фактических затрат. Для обоснования интеллектуальных решений необходимо отдельно оценивать эффект перехода от ручного планирования к VRP/VRPTW и добавочный эффект прогнозных моделей машинного обучения.

Предложенная методика предусматривает три сопоставимых сценария, единый протокол данных, систему KPI и экономическую оценку с учётом затрат на ПО. Её применение может обеспечить более прозрачное принятие решений о внедрении интеллектуальных модулей в TMS дистрибьюторских предприятий Казахстана. Дальнейшая работа предполагает апробацию на фактических доставках и проверку воспроизводимости результатов.

Список литературы:

Методическое примечание: расчёт MAE соответствует общепринятому определению ошибки регрессии; описание метрики приведено в документации scikit-learn [6]. Формулы процентного изменения, доли своевременных доставок и удельных затрат являются стандартными расчётными отношениями, адаптированными к заданному набору KPI.

© Central Asian Scientific Journal, 2026

1. Jazemi R., Alidadiani E., Ahn K., Jang J. A Review of Literature on Vehicle Routing Problems of Last-Mile Delivery in Urban Areas // Applied Sciences. — 2023. — Vol. 13, № 24. — Art. 13015. — DOI: 10.3390/app132413015.

2. Bogyrbayeva A., Meraliyev M., Mustakhov T., Dauletbayev B. Machine Learning to Solve Vehicle Routing Problems: A Survey // IEEE Transactions on Intelligent Transportation Systems. — 2024. — Vol. 25, № 6. — P. 4754–4772. — DOI: 10.1109/TITS.2023.3334976.

3. Bengio Y., Lodi A., Prouvost A. Machine Learning for Combinatorial Optimization: A Methodological Tour d'Horizon // European Journal of Operational Research. — 2021. — Vol. 290, № 2. — P. 405–421.

4. Google for Developers. Vehicle Routing Problem with Time Windows // OR-Tools Documentation. — URL: https://developers.google.com/optimization/routing/vrptw (дата обращения: 17.10.2026).

5. Бюро национальной статистики Агентства по стратегическому планированию и реформам Республики Казахстан. Официальный сайт. — URL: https://stat.gov.kz (дата обращения: 17.10.2026).

6. Scikit-learn developers. Mean absolute error // User Guide: Metrics and scoring. — URL: https://scikit-learn.org/stable/modules/model_evaluation.html#mean-absolute-error (дата обращения: 19.10.2026).

© Central Asian Scientific Journal, 2026