

Интеллектуальные модели маршрутизации пациентов в условиях чрезвычайных ситуаций – интегративный подход к оптимизации распределения

Глеб О. Бондаренко

*Национальный
исследовательский
университет ИТМО*
Olakola9@gmail.com

Анастасия Р. Попова

*Санкт-Петербургский
государственный
электротехнический
университет «ЛЭТИ»
им. В.И. Ульянова (Ленина)*
renoridoru@gmail.com

Алёна С. Сырых

*Национальный
исследовательский
университет ИТМО*
alyoshca.syryh@mail.ru

Егор В. Патока

*Национальный
исследовательский
университет ИТМО*
yegor-patoka@mail.ru

Евгений И. Гейченко

*Санкт-Петербургский
государственный
электротехнический
университет «ЛЭТИ»
им. В.И. Ульянова (Ленина)*
geychenko.1995@mail.ru

Владислав С. Павлюк

*Санкт-Петербургский
государственный
электротехнический
университет «ЛЭТИ»
им. В.И. Ульянова (Ленина)*
vlad.pavluk03@mail.ru

Аннотация. Статья посвящена созданию универсальной системы для оптимизации маршрутизации пациентов, которая может быть использована в условиях чрезвычайных ситуаций в сфере экстренной медицины. В исследовании рассматриваются различные вычислительные методы, включая сети Петри, GOAP и эволюционные алгоритмы, которые позволяют улучшить распределение медицинских ресурсов и ускорить процесс оказания помощи. Проводится детальный анализ эффективности каждого из подходов, выделяя ключевые преимущества гибкой и адаптивной системы.

Ключевые слова: маршрутизация пациентов, вычислительные модели, оптимизация распределения, экстренная медицина, чрезвычайные ситуации

I. ВВЕДЕНИЕ

В чрезвычайных ситуациях эффективность системы здравоохранения определяется способностью быстро распределять медицинские ресурсы и направлять пациентов. Непредсказуемость таких ситуаций, сопровождающихся массовым поступлением пострадавших, требует от служб экстренной медицинской помощи гибкости и быстроты реагирования. Внедрение интеллектуальных моделей маршрутизации пациентов становится ключевым инструментом для оптимизации этих процессов, позволяя быстрее и точнее принимать решения.

Ранее в области медицинской логистики применялись различные подходы к моделированию и оптимизации потоков пациентов [1]. Дискретно-событийное моделирование, широко используемое в исследовательской практике, позволяет анализировать и

прогнозировать загрузку медицинских учреждений. Например, исследования, посвященные анализу потоков пострадавших во время массовых поступлений в больницы, демонстрируют возможности использования этого метода для повышения эффективности распределения ресурсов. Имитационное моделирование также использовалось для оценки работы стационарных отделений неотложной помощи, выявляя узкие места в процессе оказания помощи и предлагая возможные пути их устранения. Однако такие системы, как FlexSimHC [2], в основном используются для оценки заранее заданных сценариев и не способны адаптироваться в реальном времени к изменяющимся ситуациям [3].

Несмотря на успешное применение таких моделей в плановых условиях, их использование в чрезвычайных ситуациях недостаточно эффективно. Одна из основных проблем заключается в их статичности: большинство существующих моделей ориентированы на заранее определенные сценарии и недостаточно гибки, чтобы адаптироваться к быстро меняющимся условиям. Кроме того, они не всегда учитывают особенности чрезвычайных ситуаций, такие как внезапный и непредсказуемый наплыв пострадавших, нехватка медицинских ресурсов и необходимость быстрого перераспределения потоков пациентов. Еще один существенный недостаток – ограниченная интеграция с системами реального времени, что затрудняет использование этих моделей в динамично развивающихся ситуациях, когда каждое решение должно основываться на актуальных данных.

Интеграция динамических моделей в процесс маршрутизации пациентов позволяет устранить существующие недостатки и адаптировать медицинские услуги к непредсказуемым условиям. Использование сетей Петри, GOAP (Goal-Oriented Action Planning) и эволюционных алгоритмов обеспечивает возможность гибко реагировать на изменения ситуации. В отличие от традиционных имитационных моделей, такие системы не просто следуют заранее заданному сценарию, а способны анализировать текущую загруженность отделений, доступность медицинских ресурсов и состояние пациентов, оперативно корректируя маршруты на основе поступающих данных.

Современные технологии искусственного интеллекта обеспечивают интеграцию с системами реального времени, позволяя медицинским службам быстро обрабатывать поступающие данные и принимать обоснованные решения. Практика экстренной медицины уже экспериментирует с внедрением таких технологий, демонстрируя значительное сокращение времени реагирования и повышение точности маршрутизации. Использование машинного обучения в сочетании с анализом жизненных показателей пациентов позволяет прогнозировать развитие ситуации и определять приоритетность оказания медицинской помощи.

Внедрение интегративных систем маршрутизации пациентов, основанных на динамических моделях, является перспективным направлением развития экстренной медицины. Такие системы способны не только повысить эффективность оказания медицинской помощи, но и оптимизировать распределение ресурсов, адаптируясь к быстро меняющимся условиям чрезвычайных ситуаций. Благодаря этому можно существенно снизить уровень перегрузки медицинских учреждений и повысить эффективность оказания помощи пострадавшим в критических ситуациях.

II. ПОСТАНОВКА ЗАДАЧИ

Рассмотрим набор агентов A и набор маркеров M , представляющих ключевые точки маршрутизации пациентов в системе экстренной медицинской помощи. Агент $a \in A$ соответствует пациенту, который должен пройти через набор маркеров M , чтобы получить медицинскую помощь. Маркеры $m \in M$ могут обозначать различные промежуточные точки внутри медицинского учреждения.

Задача состоит в построении оптимальной последовательности маркеров $\sigma = (m_1, m_2, \dots, m_k)$, которая задает маршрут пациента с минимальными затратами, учитывая динамические изменения в состоянии системы. Оптимальность маршрута определяется целевой функцией (1), минимизирующей суммарную стоимость переходов между маркерами:

$$F(\sigma) = \sum_{j=1}^{k-1} C(m_j, m_{j+1} + 1, t) \quad (1)$$

где $C(m_j, m_{j+1} + 1, t)$ – динамическая стоимость перехода между маркерами, которая изменяется во времени t в зависимости от текущего состояния системы (например, загруженность ветки, очереди, доступность ресурсов).

Каждый агент a стартует со стартового маркера m_{start} и должен достичь целевого маркера m_{goal} , проходя через необходимые промежуточные точки $M_{\text{req}} \subseteq M$. Однако маршрут должен адаптироваться к изменяющимся условиям системы, таким как изменение нагрузки на медицинские учреждения (увеличение очередей, нехватка коек), изменение доступности ресурсов (отказ оборудования, перераспределение персонала), определение приоритетности критических пациентов, требующих немедленного вмешательства.

Маршрутизация ограничена набором предикатов P , которые задают условия для переходов между лексемами. Например, предикат $p_1 = \text{«доступность операционной»}$ может блокировать переход, если все операционные заняты.

В многопользовательском сценарии, где есть несколько агентов $A_1, A_2, \dots, A_n$, нам нужно найти набор маршрутов $\{\sigma_1, \sigma_2, \dots, \sigma_n\}$.

Таким образом, задача состоит в динамическом построении маршрутов, которые минимизируют затраты на поездку и при этом адаптируются к изменяющимся условиям медицинской системы [4].

III. МЕТОДЫ

Для динамической маршрутизации пациентов в условиях чрезвычайных ситуаций было применено несколько подходов, основанных на различных математических моделях. Оптимизация потока пациентов может быть представлена через изменение стоимости перехода между маркерами с течением времени, что делает задачу поиска пути динамичной. Среди наиболее подходящих методов – сети Петри, GOAP и эволюционные алгоритмы, каждый из которых решает задачу маршрутизации по-своему [5].

В модели сети Петри поток пациентов можно представить как движение маркеров, перемещающихся между состояниями. Пусть система состоит из набора состояний S и переходов T , где каждый переход t_i возможен только при выполнении определенных условий. Маркеры в этой модели соответствуют местам $m \in M$ через которые проходит агент a . Перемещение от одного маркера к другому разрешено, если предикат $P(m_i)$ удовлетворен и необходимый ресурс $R(m_i)$ доступен. Процесс маршрутизации в сетях Петри может быть выражен (2),

$$\forall m_i \in M, \quad P(m_i) \wedge R(m_i) > 0, \quad a \rightarrow m_j \quad (2)$$

здесь $R(m_i)$ – доступность ресурса в маркере m_i , а оператор $\rightarrow$ обозначает возможность перемещения агента. Однако сети Петри плохо адаптируются к резко меняющимся условиям, они требуют пересчета всей структуры при изменении параметров системы, а также требуют завершения действий до пересчета, что делает их менее подходящими для критических ситуаций.

Эволюционные алгоритмы решают задачу маршрутизации как оптимизационную задачу на графе. Пусть X – множество возможных маршрутов, а объективная функция $F(X)$ определяет стоимость маршрута, которая зависит от длины пути, времени ожидания и доступности медицинских ресурсов.

Каждый маршрут кодируется как хромосома x_i , и его пригодность рассчитывается как (3)

$$F(x_i) = \sum_{j=1}^{k-1} C(m_j, m_{j+1} + 1, t) + \lambda \cdot W(x_i) \quad (3)$$

где $W(x_i)$ – штраф за невыполнение ограничений, а λ – коэффициент штрафа. В ходе итераций выбираются лучшие маршруты, мутации позволяют исследовать новые варианты, а кроссинговер улучшает адаптацию к изменяющимся условиям.

Подход GOAP широко используется при разработке интеллектуальных агентов, способных автономно принимать решения. Этот метод позволяет агенту формировать последовательности действий, направленных на достижение заданных целей, с учетом текущего состояния среды и ограничений. В данной работе мы предлагаем математическую формализацию GOAP, которая может послужить основой для анализа и оптимизации алгоритмов планирования.

Задача планирования в GOAP может быть представлена в виде направленного графа, где вершины соответствуют возможным состояниям системы, а ребра – действиям, которые переводят систему из одного состояния в другое. Поиск плана сводится к нахождению пути в этом графе из начального состояния S_{start} в состояние цели S_{goal} . Формально задача планирования задается кортежем $\langle S, A, S_{start}, S_{goal} \rangle$, где S – множество состояний, A – множество действий, S_{start} – начальное состояние, а S_{goal} – целевое состояние. Цель планирования – найти последовательность действий $P_G = (a_1, a_2, \dots, a_k)$ такую, что (4):

$$S_{goal} = a_k \cdot a_{k-1} \cdot \dots \cdot a_1(S_{start}) \quad (4)$$

Эта последовательность должна удовлетворять всем предварительным условиям и ограничениям, наложенным на действия.

В реальных задачах часто возникают дополнительные ограничения, такие как ограничения на порядок выполнения действий или ограничения на ресурсы. Например, действие a_1 может потребовать выполнения действия a_2 перед своим выполнением. Такие ограничения могут быть выражены с помощью дополнительных переменных состояния или логических условий.

Таким образом, модели сетей Петри обеспечивают детерминированные процессы, но не учитывают неожиданные изменения. GOAP позволяет адаптироваться к динамическим условиям, прерывая и перестраивая планы в реальном времени. Эволюционные алгоритмы позволяют находить оптимальные маршруты, адаптируясь к сложным многомерным ограничениям системы. В совокупности эти методы могут учитывать потоки пациентов, динамические нагрузки на отделения и изменение доступности ресурсов, что делает их применимыми для решения задач экстренной медицины.

IV. РЕЗУЛЬТАТЫ

Сети Петри, как имитационная модель, демонстрируют строгую последовательность выполнения задач. Результаты тестирования системы на

основе сетей Петри показаны на рис. 1. Критические пациенты (красный график) и некритические пациенты (синий график) обслуживаются с одинаковой скоростью, что видно по практически идентичным распределениям. Это связано с тем, что модель не может переключаться между задачами до тех пор, пока не будет завершена текущая задача. В результате критический пациент в лучшем случае будет обслуживаться с той же скоростью, что и остальные, что делает эту модель неэффективной в условиях, когда требуется расстановка приоритетов. Основным преимуществом сетей Петри является их предсказуемость и простота моделирования, однако они плохо подходят для задач, требующих динамического перераспределения ресурсов.




Рис. 1. Результаты работы модели сетей Петри

GOAP демонстрирует способность динамически перераспределять ресурсы и изменять маршруты в режиме реального времени. Результаты тестирования системы GOAP показаны на рис. 2. Критические пациенты (красный график) обслуживаются быстрее, чем обычные (синий график), что видно по более крутому спаду красной кривой. Это достигается за счет прерывания текущего плана, если на пути встречается критический пациент. Однако GOAP не может заранее предсказать появление критических пациентов и заранее оптимизировать маршрут. В результате система вынуждена сначала выбрать «ложный» путь, уступить дорогу критическому пациенту и только потом продолжить выполнение плана. Это сокращает время оказания помощи критическим пациентам, но увеличивает время ожидания для обычных пациентов.




Рис. 2. Результаты работы модели GOAP

Генетические алгоритмы справились с этой задачей хуже. Результаты тестирования системы на основе генетических алгоритмов показаны на рис. 3. Несмотря на наличие штрафов за неуступку дороги критическим пациентам, модель не может явно связать штрафы с необходимостью уступить дорогу. Это делает поведение системы непредсказуемым и снижает ее эффективность. В лучшем случае генетические алгоритмы требуют доработки, например интеграции с Reinforcement Learning, чтобы улучшить их способность адаптироваться и принимать решения в режиме реального времени.




Рис. 3. Результаты работы генетической модели

V. Выводы

Это исследование трех моделей – сетей Петри, GOAP и генетических алгоритмов – выявило их сильные и слабые стороны в контексте управления ресурсами для ухода за пациентами в условиях, когда требуется критическая приоритизация случаев. Каждая из моделей обладает уникальными характеристиками, которые делают их подходящими для определенных сценариев, но также указывают на их недостатки.

Сети Петри показали себя как надежная и предсказуемая имитационная модель, идеально подходящая для задач, где требуется строгая последовательность действий. Однако их главный недостаток – неспособность к динамическому перераспределению ресурсов. В условиях, когда критически важные пациенты должны быть приоритетными, сети Петри неэффективны, поскольку они не могут прервать текущие задачи, чтобы заняться более срочными случаями. Это делает их применимыми только в стабильной среде, где приоритеты не меняются в реальном времени.

С другой стороны, GOAP продемонстрировала высокую гибкость и адаптивность. Его способность перестраивать планы в режиме реального времени позволяет ему быстро реагировать на появление критических пациентов, что проявляется в более оперативной работе с такими случаями. Однако за эту гибкость приходится платить: GOAP не может заранее предсказать прибытие критических пациентов, что приводит к необходимости корректировать маршруты уже во время выполнения плана. Это увеличивает время обслуживания обычных пациентов, что может негативно сказаться на их состоянии. Таким образом, GOAP лучше всего подходит для сред, где динамическое изменение приоритетов является нормой, но требует дополнительных механизмов для оптимизации маршрутов.

Генетические алгоритмы оказались наименее эффективными в решении этой задачи. Несмотря на их способность находить оптимальные решения в сложных условиях, в текущей реализации не было явного учета необходимости определения приоритетов для критически важных пациентов. Штрафы за несоблюдение правил дорожного движения не были в достаточной степени связаны с конкретными действиями, что привело к непредсказуемому поведению системы. Для улучшения результатов требуется интеграция с более сложными методами, такими как обучение с подкреплением, чтобы модель могла лучше адаптироваться к изменяющимся условиям и принимать более обоснованные решения.

СПИСОК ЛИТЕРАТУРЫ

- [1] Цебровская Н.В. «Возможности имитационного моделирования в практике системы здравоохранения» // Бюллетень медицинских интернет-конференций, т. 13, № 2, с. 145-150, 2023.
- [2] Пальмов С.В., Жуйкова А.А. «Обзор возможностей системы имитационного моделирования FlexSim в области здравоохранения» // Системный анализ и управление в биомедицинских системах, т. 21, № 4, с. 98-105, 2022.
- [3] J. Guo, 'Application of Operations Research to Healthcare', New Research in Nursing - Education and Practice // IntechOpen, Nov. 15, 2023. doi: 10.5772/intechopen.109919.
- [4] Guo J, Bard JF. A column generation-based algorithm for midterm nurse scheduling with specialized constraints, preference considerations, and overtime // Computers and Operations Research. 2022;138(2022):105597. DOI: 10.1016/j.cor.2021.105597.
- [5] Bahadori-Chinibelagh S, Fathollahi-Fard AM, Hajiaghahi-Keshteli M. Two constructive algorithms to address a multi-depot home healthcare routing problem // IETE Journal of Research. 2019;68(3):1-7. DOI: 10.1080/03772063.2019.1642802