

Интеллектуальные системы в клинической медицине. Синтез плана лечения на основе прецедентов

Г.И. Назаренко, Г.С. Осипов, А.Г. Назаренко, А.И. Молодченков

Аннотация. В работе рассматривается применение систем правил в задачах клинической медицины. Рассматривается формирование правил по примерам на основе AQ метода. Предлагается метод синтеза плана лечения по прецедентам.

Ключевые слова: клиническая медицина; системы, основанные на правилах; машинное обучение; план лечения, прецедент.

Введение

Применение методов искусственного интеллекта в медицине обычно связывают с возникновением экспертных систем в середине восьмидесятых годов прошлого века как результата 30-летнего академического периода исследований в области искусственного интеллекта. основополагающие соображения на этот счет высказал Э. Фейгенбаум на 5-й Объединенной конференции по искусственному интеллекту в 1977 году. Суть их состояла в том, что специалисты достигают высоких результатов, накапливая знания и опыт; если же интеллектуальные программы будут устроены так, что смогут действовать подобным образом, то и они смогут достичь высоких результатов.

Одной из первых систем, использовавших знания для решения задач была экспертная система DENDRAL [1], разработанная в Стэнфордском университете и предназначенная для порождения формул химических соединений на основе спектрального анализа. В настоящее время DENDRAL поставляется покупателям вместе со спектрометром. Первой собственно медицинской экспертной системой стала система MYCIN

[2], предназначенная для диагностики и лечения инфекционных заболеваний крови.

Система CASNET [3] предназначена для диагностики и выбора стратегии лечения глаукомы. Система DXplain [4] – пример интеллектуальной системы поддержки клинических решений, используется для ассистирования в процессе диагностики и содержит в своей базе знаний симптомы, лабораторные данные и процедуры, связывающие их со списком диагнозов. Она обеспечивает поддержку и обоснование дифференциальных диагнозов и последующих исследований [5]. В её базе данных содержится 4500 клинических манифестаций, которые связаны ассоциативными связями более чем с 2000 различных нозологий.

Система Germwatcher [6] была разработана в помощь больничному эпидемиологу. Содержит большой объем данных по различным микробиологическим культурам. Включает базу знаний, основанную на правилах, которая используется для генерации гипотез о возможных инфекциях.

Система PEIRS [7] интерпретирует и комментирует отчеты по химическим патологиям. В систему встроен модуль автоматического машинного обучения, который позволяет пато-

логу создавать новые правила без участия инженера по знаниям. В настоящее время создано 2300 таких правил. На построение каждого нового правила требуется около минуты. Ежедневно система комментирует 100 отчетов в области газового состава артериальной крови, теста толерантности глюкозы и др. Система Puff [8] предназначена для интерпретации результатов функционального пульмонологического теста. Она использует прецедентную информацию; в её базе прецедентов содержатся десятки тысяч случаев. Имеется коммерческая версия системы, несколько сотен копий которой внедрено в ряде стран.

Среди отечественных разработок отметим систему для синдромной диагностики неотложных состояний у детей ДИН [9], созданную в Московском НИИ педиатрии и детской хирургии. Эта система содержит информацию о 42 синдромах, которые представляют собой список диагностических предложений-гипотез. Так как выбор лечения во многом определяется прогнозом возможных осложнений, в системе описаны взаимосвязи синдромов, определяемые причинно-следственными, временными и ассоциативными отношениями.

Программный комплекс Айболит [10] предназначен для диагностики, классификации и коррекции терапии острых расстройств кровообращения у детей. Он создан в Центре сердечно-сосудистой хирургии имени А.Н. Бакулева и активно применяется при оперативных вмешательствах и выборе послеоперационного лечения в условиях реанимационного отделения. Система включает математическую модель кровообращения, «реагирующую» на поступающую с датчиков текущую информацию. Она позволяет не только проводить диагностику и оценку состояния больного, но и помогать при выборе и последующей коррекции лечебных мероприятий.

Система HELP [11] – полная госпитальная информационная система, основанная на технологиях искусственного интеллекта. Она поддерживает не только стандартные функции госпитальных информационных систем, но функции поддержки принятия решений. Эти функции инкорпорированы в рутинные приложения госпитальной системы. Они поддержи-

вают клинический процесс тревожными сигналами и напоминаниями, интерпретацией данных, выработкой предложений по управлению процессом лечения и клиническими протоколами. Эти функции могут активироваться из обычных приложений или включаться самостоятельно после ввода клинических данных в компьютерную историю болезни.

Отметим ещё систему SETH [12], область применения которой анализ токсичности лекарственных средств. Система основана на моделировании экспертных рассуждений, для каждого токсикологического класса учитывающих клинические симптомы и применяемые дозы. Система выполняет мониторинг лечебного процесса, направленный на контроль взаимодействия взаимодействия лекарств.

Итак, сегодня технологии искусственного интеллекта применяются в самых различных областях клинической медицины. Кратко охарактеризуем эти области.

Подача тревожных сигналов и напоминаний. Речь идет о мониторинге пациентов в реальном времени посредством прикроватных мониторов. Экспертные системы встраиваются в такие мониторы и оценивают состояния пациентов и их изменения. Они могут также напоминать о необходимости или порядке приема лекарств и посылать напоминания, например, по электронной почте.

Ассистирование в процессе диагностики. В сложных случаях или в случаях недостаточного опыта диагноста соответствующая экспертная система может оказать помощь на основе исследования данных о пациенте.

Поиск подходящих случаев (прецедентов). Например, в интернете или в локальной базе данных. Такая интеллектуальная система (агент) должна обладать знаниями об основных характеристиках пациента и понимать, что в каждом случае означает слово «подходящий».

Контроль и планирование терапии. Интеллектуальная система может контролировать неполноту, ошибки существующего лечебного процесса или недостаточный учет специфических характеристик пациента в принятом плане лечения.

Распознавание и интерпретация образов. Достаточно большое число медицинских обра-

зов допускают автоматическую интерпретацию: от плоских рентгеновских снимков до более сложных образов наподобие ангиограмм и результатов томографических исследований.

Таким образом, речь идёт о широком применении интеллектуальных систем в различных областях медицины. Это обстоятельство требует анализа их теоретических основ для дальнейшего расширения сферы применения.

В настоящей работе рассмотрены особенности медицинских экспертных систем (МЭС), в качестве основного способа представления знаний в которых выступают системы правил, и предложены некоторые механизмы, расширяющие возможности их использования в клинической медицине.

1. Архитектурные особенности МЭС, основанных на правилах

Один из наиболее распространенных подходов предусматривает выделение на самом высоком уровне описания экспертных систем следующих трех компонент: *рабочей памяти* (или, как иногда говорят, *глобальной базы данных*), *множества правил*, выполняющих некоторые действия в рабочей памяти (а иногда и во внешней среде) и некоторой *стратегии управления*, в соответствии с которой происходит выбор правил для применения.

Правила применяются к рабочей памяти. В состав каждого правила входит *условие*, которому текущее состояние рабочей памяти может либо удовлетворять, либо нет. Правило может быть *применено*, если условие выполнено. Применение правила, вообще говоря, изменяет состояние рабочей памяти. Стратегия управления выбирает, какое именно правило из числа применимых следует использовать и прекращает вычисления, когда состояние рабочей памяти удовлетворяет целевому условию.

С точки зрения архитектуры такой подход обладает следующими существенными отличиями от архитектур традиционных программных систем:

- рабочая память доступна всем правилам;
- отсутствуют вызовы правил из других правил;

- отсутствует априорно заданный алгоритм решения задачи (т.е. порядок выполнения правил), алгоритм решения задачи является одним из результатов её решения;

- данные и результаты вычислений становятся доступными правилам только через рабочую память.

Далее перейдем к более детальному изложению основных архитектурных идей систем такого рода [13, 14].

1.1. Правила для представления знаний

Определение 1.1. *Правил*ом называется упорядоченная тройка множеств $\Pi = \langle C, A, D \rangle$,

где C – условие правила;

A – множество добавляемых правилом фактов;

D – множество фактов, удаляемых правилом.

В правилах атомарные формулы P_1, P_2, \dots из множеств C, A и D превращаются в факты в процессе *применения* правила, т.е. в результате выполнения соответствующих подстановок (m_1, m_2, \dots, m_n) на места свободных переменных (x_1, x_2, \dots, x_n) и проверки для каждой формулы $P_i(x_1, x_2, \dots, x_n)$ из C условия $(m_1, m_2, \dots, m_n) \in I(P_i)$, т.е. выполнимости формулы в текущем состоянии рабочей памяти.

Определение 1.2. Будем говорить, что условие правила выполнено, если в текущем состоянии рабочей памяти выполнена каждая из атомарных формул условия.

Определение 1.3. Правило применимо к состоянию рабочей памяти, если его условие выполнено в этом состоянии.

1.2. Рабочая память

Рабочая память должна быть согласована с множеством правил. Такое согласование выполняется следующим образом: пусть Π – некоторое множество правил; C, A и D – объединения условий, множеств добавляемых фактов и множеств удаляемых фактов по всему множеству Π . M – множество индивидов предметной области. Тогда для каждой n – местной атомарной формулы $P(x, y, \dots, z) \in C \cup A \cup D$ рабочая память должна содержать n – местное конечное отношение $I(P) \subseteq M^n$, где I – интерпретирующее отображение (Рис.1)




Рис. 1. (Стрелками показано отображение I)

1.3. Стратегии управления

Стратегия управления предназначена для организации процесса вычислений.

В самом общем виде её можно описать следующим образом:

Шаг 1 выбрать очередное правило из множества правил;

Шаг 2 проверить выполнимость условия правила в текущем состоянии рабочей памяти;

Шаг 3 если условие правила выполнено, поместить правило в конфликтное множество;

Шаг 4 если множество применимых правил исчерпано, выбрать какое-либо правило из конфликтного множества правил и применить его;

Шаг 5 перейти к шагу 1.

Условиями остановки являются пустое конфликтное множество, либо получение решения.

2. Особенности применения МЭС, основанных на правилах, для решения медицинских задач

2.1. Задачи дифференциальной диагностики

В диагностических задачах в качестве фактов выступают манифестации, симптомы, диагностические признаки - как положительные, так и отрицательные или исключаяющие; так называемые обусловленные признаки - признаки, отсутствие которых обладает большим диагностическим значением, чем их присутствие. В качестве специального подмножества множества фактов выступает множество нозологических форм. В процессе диагностики некоторые из них выступают в роли гипотез, которые, в свою очередь, приобретают статус диагнозов по завершении диагностического процесса. С содержательной точки зрения симптомы и признаки являются следствиями тех или иных за-

болеваний, и поэтому при построении правил следует правильно учитывать существующие каузальные связи.

В самом общем случае при построении правил дифференциальной диагностики следует выделять следующие их виды:

а) правила, пополняющие множество гипотез на основе учета положительных признаков P^+ ; эти правила (в более привычной записи) имеют вид: <УСЛОВИЕ> <СПИСОК ДОБАВЛЯЕМЫХ ФАКТОВ>.

В правилах такого вида в качестве условия выступает некоторое множество симптомов (манифестаций, признаков), а в качестве списка добавляемых фактов – возможные заболевания (нозологические формы), пополняющие множество гипотез H ;

б) правила, пополняющие множество учитываемых признаков P на основе расширенного множества гипотез H ; формально эти правила выглядят так же, как правила типа (а), однако роль условия в них играют гипотезы из расширенного множества гипотез, а роль добавляемых фактов – новые признаки, которые не были учтены на первых итерациях правил типа (а) и которые должны быть подвергнуты исследованию (или тестированию);

в) правила, редуцирующие множество гипотез H на основе учета исключяющих признаков P^- ; эти правила имеют вид:

<УСЛОВИЕ> <СПИСОК УДАЛЯЕМЫХ ФАКТОВ>.

В условии этого правила содержатся признаки, выполнение (наличие) которых исключает из множества H гипотезы, содержащиеся в списке удаляемых фактов.

г) правила, редуцирующие множество гипотез на основе учета отсутствующих обусловленных признаков. Выглядят они так же, как и правила типа (в), однако применяются в случае ложности условия.

д) последний тип правил - правила дифференцирования множества гипотез. На самом деле – это метаправила и выглядят они, в простейшем случае, следующим образом:

если правило П1 содержит в списке добавляемых фактов множество гипотез $h1 \subset H$, а правило П2 – множество гипотез $h2 \subset H$ и $\langle \text{УСЛОВИЕ} \rangle(\text{П1}) \subset \langle \text{УСЛОВИЕ} \rangle(\text{П2})$, то множество гипотез $h1$ удаляется из списка гипотез H .

Возможны и правила некоторых иных типов, но сейчас мы не будем останавливаться на них, а перейдем к стратегии управления D. Идея её состоит в последовательном испытании правил каждого из типов и применении тех из них, условия которых окажутся выполненными в текущем состоянии рабочей памяти.

2.2. Стратегия D (дифференциальной диагностики)

Шаг 1. Выбрать очередное правило типа (а), проверить выполнимость его условия в текущем состоянии рабочей памяти и, если условие выполнено, применить правило, т.е. пополнить множество гипотез H .

Шаг 2. Выбрать очередное правило типа (б), проверить выполнимость его условия на текущем множестве гипотез H и, если условие выполнено, применить правило. Применение правила здесь означает пополнение множества признаков P , причем, разумеется, такими признаками, которые до этого в P отсутствовали (это требование содержательное, на самом деле за этим можно не следить, т.к. «склеивание» совпадающих признаков будет выполняться автоматически). Перейти к Шагу 1.

Шаги 1 и 2 должны выполняться попеременно до стабилизации множеств P и H .

Выполнение этих шагов гарантирует, что ни один признак и ни одна из возможных гипотез, имеющих хотя бы отдалённое отношение к состоянию больного, не будут упущены.

Шаг 3. Выбрать очередное правило типа (в), проверить его выполнимость на множестве признаков P и, если его условие выполнено, применить его.

Повторять Шаг 3 до стабилизации множества H .

В результате выполнения цикла правил типа (в) из множества гипотез H будут исключены

все гипотезы, для которых известны и выполнены исключающие признаки.

Шаг 4. Выбрать очередное правило П1 типа (д). Если среди правил типа (д) для него найдется правило П2, такое что $\langle \text{УСЛОВИЕ} \rangle(\text{П1}) \subset \langle \text{УСЛОВИЕ} \rangle(\text{П2})$, то из H удаляются все гипотезы $h1$, содержащиеся в списке добавляемых фактов правила П1. Шаг 4 повторяется до стабилизации множества H .

На этом шаге стратегия завершает свою работу. Полученное множество H и будет результатом дифференциальной диагностики.

Подчеркнем, стратегия D ни в коем случае не является алгоритмом дифференциальной диагностики, т.к. не содержит знаний о конкретных нозологиях, их признаках, симптомах, симптомокомплексах и синдромах. Вся такая информация должна содержаться в правилах, типы которых здесь описаны. Собственно диагностический алгоритм, т.е., последовательность примененных правил, результатом которых является диагноз, возникает в результате взаимодействия описанной стратегии и множества правил.

Преимущество описанной здесь архитектуры состоит в том, что стратегия D применима к любому набору правил, а это означает, что построенную на её основе систему можно постоянно совершенствовать, редактируя как сами правила, так и их состав без перепрограммирования системы, сохраняя ее работоспособность. Для этого нужен лишь достаточно удобный интерфейс. Кроме того, множество правил может пополняться благодаря применению методов машинного обучения или обучения по примерам и прецедентам без нарушения работоспособности системы. Ниже мы несколько подробнее обсудим применение прецедентов и машинного обучения в медицине.

3. Применение индуктивных методов машинного обучения

Как мы видели, описанный выше подход использует правила в качестве способа представления знаний. Таким образом, уместен вопрос: откуда же берутся требуемые правила? Иначе говоря, каковы источники знаний для построения экспертных систем?

В качестве таковых обычно выступают:

- специалисты предметных областей, обычно называемые экспертами;
- протоколы рассуждений (протоколы "мыслей вслух") экспертов;
- протоколы так называемых диагностических игр;
- книги, инструкции;
- примеры и прецеденты решения соответствующих задач (например, диагностики или выбора схемы лечения);
- базы медицинских данных (например, электронные истории болезней).

Приобретение экспертными системами знаний от экспертов и из текстов различного рода описано в [15-17]. Здесь же мы рассмотрим методы обучения экспертных систем по примерам, т.е. такие методы приобретения знаний медицинскими экспертными системами, в которых в качестве источников знаний выступают примеры и прецеденты решения различных медицинских задач и данные, содержащиеся в базах данных, точнее, в медицинских информационных системах.

Существуют различные типы методов такого рода, которые условно можно разбить на три класса: статистические, индуктивные и нейросетевые.

Здесь мы сосредоточим внимание на втором классе методов, особенность которых состоит в том, что они не требуют представительных или, как говорят, репрезентативных выборок данных и, кроме того, могут довольствоваться небольшим количеством примеров.

Среди индуктивных методов, в свою очередь, можно выделить методы ближайших соседей, методы построения деревьев решений, методы покрытий и другие. Здесь мы продемонстрируем возможности метода последовательных покрытий для автоматического построения правил.

Этот метод основан на идее постепенного покрытия обучающих данных с помощью последовательно порождаемых правил и используется целым семейством алгоритмов [18]. При поиске правил следует действовать таким образом, чтобы порождаемые правила покрывали все положительные примеры и ни одного отрицательного.

В привычной записи порождаемые алгоритмом правила будут иметь вид:

если A_1 и A_2 и ... и A_n , то C

где C — заключение, а условия A_i могут быть записаны в так называемой атрибутивной форме $at_i = V$, где at_i — имя атрибута или признака, а V — его значение, или иметь более общий вид $at_i = v_1 \vee v_2 \vee v_3 \dots$, где атрибут может принимать одно из нескольких значений (связанных дизъюнкциями).

Опишем этот алгоритм в общем виде:

Шаг 1. Разделить все примеры на подмножества PE положительных примеров и NE отрицательных примеров.

Шаг 2. Выбрать из PE случайным образом или по каким-то соображениям один пример, который будет считаться опорным примером.

Шаг 3. Найти множество максимально общих правил, характеризующих опорный пример. Предел обобщения определяется множеством NE : обобщенное описание опорного примера не должно удовлетворять ни одному объекту из NE . Полученное таким образом множество правил называется опорным множеством.

Шаг 4. Используя некоторый *критерий предпочтения*, выбрать лучшее правило в опорном множестве.

Шаг 5. Если это правило, вместе с ранее порожденными таким образом правилами, покрывает все объекты из PE , то конец. Иначе — найти другой опорный пример среди неохваченных примеров в PE и перейти к 3.

Шаг 3 выполняется специальной *процедурой порождения* опорного множества правил. Критерий предпочтения для выбора правил на шаге 4 определяется характером решаемой задачи. Таким критерием может выступать комбинация различных элементарных критериев, таких как требование максимального числа положительных примеров, описываемых правилом, минимального числа используемых атрибутов, максимальной оценки степени общности, т.е. отношения числа положительных примеров, покрываемых правилом, к числу всех примеров, минимальных затрат на измерение значений атрибутов и т.п. Кроме того, можно использовать критерии выбора атрибутов, такие как энтропия, информационная функция полез-

Признаки, примеры	Анталгический наклон туловища	Интенсивность болевого синдрома по шкале болевого аудита (от 0-120) >60 это край	Ахиллов рефлекс	Чувствительность в промежности	Чувствительность по дерматому S1	Сила в стопе (разгибание)	Мочеиспускание
П1	есть	41- 120	отсутствует	изменена	изменена	парез	затруднено
П2	есть	41- 120	норма	норма	изменена	парез	затруднено
П3	есть	41- 120	норма	изменена	изменена	норма	норма
П4	нет	0-20	норма	не изменена	не изменена	норма	норма
П5	нет	21-40	отсутствует	не изменена	изменена	норма	затруднено
П6	нет	41-69	отсутствует	изменена	изменена	парез	затруднено
П7	есть	>60	норма	норма	изменена	норма	норма

ности и т.д. Алгоритм позволяет также строить множество правил с различными отношениями между отдельными правилами.

Проиллюстрируем работу алгоритма на простом примере построения правил определения тяжести обострения протрузии межпозвонкового диска на уровне L5-S1 позвонков. Пациенту выполнено МРТ – исследование и назначено консервативное лечение. Разумеется, пример будет носить модельный характер и предназначен для иллюстрации процесса обнаружения правил - рассмотрение примеров реального уровня сложности требует больших объемов вычислений и возможно только с применением современных вычислительных средств.

В качестве обучающей выборки возьмем примеры тяжести обострения протрузии межпозвонкового диска на уровне L5-S1 позвонков: в таблице примеры 1-3 соответствуют тяжелому обострению, примеры 4-7 – не тяжелому обострению. Каждый пример задан набором признаков и их значений.

Для простоты возьмём семь признаков: анталгический наклон туловища, интенсивность болевого синдрома по шкале болевого аудита (от 0-120), Ахиллов рефлекс, чувствительность в промежности, чувствительность по дерматому S1, сила в стопе (разгибание), мочеиспускание.

Каждая строка соответствует одному вектору значений признаков. Предположим, критерий предпочтения рекомендует выбирать правила, охватывающие максимально возможное число положительных примеров, а условия правил могут пересекаться друг с другом. Программа обнаружения правил диагностики тяжелого обострения по приведенным примерам будет состоять из следующих шагов:

Выбрать первый опорный пример, например, П1.

Для построения опорного множества примера П1 (т.е. множества максимально общих описаний П1), начать с построения множества всех описаний П1, которым не удовлетворяют отрицательные примеры.

Для этого обобщим какой-либо признак опорного примера, например, *Ахиллов рефлекс*. При <Ахиллов рефлекс> = отсутствует ∨ норма, правило R1 таково:

ЕСЛИ: (Анталгический наклон туловища = есть) & (Интенсивность болевого синдрома по шкале болевого аудита = 41-120) & (Ахиллов рефлекс = (отсутствует ∨ норма)) & (Чувствительность в промежности = изменена) & (Чувствительность по дерматому S1 = изменена) & (Сила в стопе (разгибание) = парез) & (Мочеиспускание = затруднительно),

ТО Обострение тяжелое

Далее займёмся атрибутом *Чувствительность в промежности* и попытаемся его обобщить. Получим в результате правило

R1 таково: ЕСЛИ: (Анталгический наклон туловища = есть) & (Интенсивность болевого синдрома по шкале болевого аудита = 41-120) & (Ахиллов рефлекс = (отсутствует ∨ норма)) & (Чувствительность в промежности = (изменена ∨ норма) & (Чувствительность по дерматому S1 = изменена) & (Сила в стопе (разгибание) = парез) & (Мочеиспускание = затруднительно)

ТО Обострение тяжелое

Результатом обобщения атрибута *Сила в стопе (разгибание)* будет правило

R1 таково: ЕСЛИ: (Анталгический наклон туловища = есть) & (Интенсивность болевого синдрома по шкале болевого аудита = 41-120) & (Ахиллов рефлекс = (отсутствует ∨ норма)) & (Чувствительность в промежности = (изменена ∨ норма) & (Чувствительность по дерматому S1 = изменена) & (Сила в стопе (разгибание) = (парез ∨ норма)) & (Мочеиспускание = затруднительно)

ТО Обострение тяжелое

Попытки дальнейшего обобщения этого описания приводят к тому, что ему начинают удовлетворять и отрицательные примеры. Например, обобщение атрибута *Мочеиспускание* приводит к правилу

R1': (Анталгический наклон туловища = есть) & (Интенсивность болевого синдрома по шкале болевого аудита = 41-120) & (Ахиллов рефлекс = (отсутствует ∨ норма)) & (Чувствительность в промежности = (изменена ∨ норма) & (Чувствительность по дерматому S1 = изменена) & (Сила в стопе (разгибание) = (парез ∨ норма)) & (Мочеиспускание = затруднительно ∨ норма), покрывающее пример 7, который не относится к тяжелому обострению протрузии межпозвоночного диска на уровне L5-S1. Поэтому правило R1' мы вынуждены отбросить. Однако оставшееся правило R1 покрывает примеры 1 и 2. Остался «неохваченным» пример 3.

Возьмем ПЗ в качестве следующего опорного примера и попытаемся его обобщить.

Процесс обобщения, начиная с признака *Ахиллов рефлекс* примера ПЗ, приводит к уже полученному правилу R1, поэтому займемся обобщением с последнего атрибута, который не был обобщен ранее, и получим правило

R2: ЕСЛИ (Анталгический наклон туловища = есть) & (Интенсивность болевого синдрома по шкале болевого аудита = 41-120) & (Ахиллов рефлекс = (отсутствует ∨ норма)) & (Чувствительность в промежности = изменена) & (Чувствительность по дерматому S1 = изменена) & (Сила в стопе (разгибание) = (парез ∨ норма)) & (Мочеиспускание = затруднительно ∨ норма)

ТО Обострение тяжелое.

Итак, поскольку неохваченных примеров больше не осталось, то два правила

R1: ЕСЛИ: (Анталгический наклон туловища = есть) & (Интенсивность болевого синдрома по шкале болевого аудита = 41-120) & (Ахиллов рефлекс = (отсутствует ∨ норма)) & (Чувствительность в промежности = (изменена ∨ норма) & (Чувствительность по дерматому S1 = изменена) & (Сила в стопе (разгибание) = (парез ∨ норма)) & (Мочеиспускание = затруднительно),

ТО Степень обострения = Тяжелое и

R2: ЕСЛИ (Анталгический наклон туловища = есть) & (Интенсивность болевого синдрома по шкале болевого аудита = 41-120) & (Ахиллов рефлекс = (отсутствует ∨ норма)) & (Чувствительность в промежности = изменена) & (Чувствительность по дерматому S1 = изменена) & (Сила в стопе (разгибание) = (парез ∨ норма)) & (Мочеиспускание = затруднительно ∨ норма),

ТО Степень обострения = Тяжелое
дают полное и непротиворечивое описание представленной в таблице ситуации.

4. Особенности использования систем правил

В этом разделе рассмотрим синтез плана лечения или иначе - лечебно-диагностической последовательности правил - по прецедентам.

Неформально прецедент (например, хранящийся в базе данных) имеет вид:

<ОПИСАНИЕ СОСТОЯНИЯ> <РЕШЕНИЕ>.

Если речь идет о диагностике, то описание состояния включает множество симптомов, признаков, инструментальных данных, данных анамнеза, а решение - диагноз. Если речь идет о лечении, то в качестве решения выступает лечебное мероприятие или их последовательность. Ситуация (состояние), для которой ищется решение, называется обычно проблемной ситуацией, или проблемой, и её неформальное описание имеет вид <ПРОБЛЕМА><РЕШЕНИЕ?>

Опишем кратко предлагаемый нами метод синтеза плана лечения на основе прецедентов (САС метод). Основными фазами метода являются: а) идентификация текущего состояния пациента, б) поиск подходящего прецедента и в) использование найденного прецедента для

выработки последовательности лечебно-диагностических мероприятий. Эта последняя задача называется иногда задачей адаптации (имеющегося решения к новой проблеме).

Задача идентификации текущего состояния пациента была описана нами в [19], поэтому здесь коротко остановимся на задачах (б) и (в).

4.1. Поиск подходящего прецедента

Для этого вначале рассмотрим понятие близости прецедентов. Для уточнения понятия близости обычно используются некоторые метрики.

Однако особенность рассматриваемых здесь задач состоит в том, что для уточнения понятия близости требуется не только метрическая характеристика близости прецедентов, но и некоторая другая их характеристика, которая позволяет сделать вывод о степени соответствия структур прецедентов. Для этой цели мы введем понятие согласования структур прецедентов. Согласование можно рассматривать как количественную характеристику близости структур прецедентов.

Для этой цели следует ввести функции согласования – локальную и глобальную.

Локальную функцию согласования можно рассматривать как меру сравнимости элементов e_1 и e двух прецедентов. (Для простоты каждый элемент можно полагать состоящим из имени признака и его значения).

Если элементы e_1 и e несравнимы, то локальная функция согласования на них не определена.

Если E – множество элементов, упомянутых выше, то локальная функция согласования $\lambda: E \times E \rightarrow R$ такова, что $\lambda(e, e_1) = r \in R$.

Содержательно сравнимость элементов e и e_1 означает, что они принадлежат одному и тому же типу или домену и тогда $\lambda(e, e_1) > 0$ может рассматриваться как сопоставимость e_1 с e ; $\lambda(e, e_1) = 0$ означает, что один из элементов не является существенным, а $\lambda(e, e_1) < 0$ указывает, что e и e_1 несопоставимы.

Используя локальную функцию согласования, можно определить глобальную функцию согласования $\Lambda: \Pi(E) \times \Pi(E) \rightarrow R$, где $\Pi(E)$ – множество прецедентов, определенных на элементах из E , R - множество рациональных чи-

сел; $\Lambda(\pi_i, \pi_j) > \Lambda(\pi_i, \pi_k)$ свидетельствует о том, что прецеденты π_i и π_j более согласованы, чем прецеденты π_i и π_k . Отрицательные значения этой функции интерпретируются как рассогласование прецедентов.

Если ввести функцию ϕ - композиции, где ϕ может быть, например, линейной формой локальных функций согласования λ_{ij} , коэффициенты которой g_{ij} являются весами соответствующих значений локальных функций, то глобальную функцию согласования Λ можно выразить через локальные следующим образом:

$$\Lambda((q_1, \dots, q_n), (e_1, \dots, e_m)) = \sum_{i=1}^n \sum_{j=1}^m g_{ij} \cdot \lambda_{ij}(q_i, e_j) \quad (i=1, \dots, n, j=1, 2, \dots, m),$$

где q_1, \dots, q_n - элементы прецедента π_1 , а e_1, \dots, e_m – элементы прецедента π_2 .

Собственно релевантность прецедента некоторому элементу характеризуется частичной функцией релевантности $\rho: E \times \Pi(E) \rightarrow R$, так что $r = \rho(q, \pi)$, где $q \in E$ – элемент, $\pi \in \Pi(E)$ – прецедент. Глобальную функцию релевантности, характеризующую релевантность прецедента π_2 прецеденту π_1 , будем для простоты считать линейной формой частичных функций релевантности:

$$\text{rel}(\pi_1, \pi_2) = \phi(\rho(e_1, \pi_2), \dots, \rho(e_n, \pi_2)),$$

где e_1, \dots, e_n – элементы π_1 .

Таким образом, поиск подходящего прецедента включает две фазы:

- поиск для проблемного прецедента π_1 множества наиболее согласованных с ним прецедентов Π^+ ;
- выбор из множества Π^+ наиболее релевантного для π_1 прецедента π_2 .

На следующем шаге следует выполнить адаптацию найденного (или найденных) релевантных проблеме π_1 прецедентов.

4.2. Адаптация прецедентов

Существует значительное число методов адаптации, используемых в различных исследованиях. Для задач клинической медицины эти методы развиты, пожалуй, в наименьшей степени. Тем не менее, большую часть имеющихся подходов можно отнести к одному из трех классов: подстановочная адаптация; трансформационная адаптация, генеративная адаптация.

Подстановочная адаптация является наиболее простым видом адаптации, предполагающим, что искомый прецедент очень близок к проблемному состоянию пациента. Тогда адаптация сводится лишь к замене некоторых параметров в решениях найденных прецедентов. Такой метод адаптации применяется в задачах идентификации и прогнозирования.

Трансформационная адаптация предусматривает реорганизацию элементов решений и позволяет добавлять и удалять эти элементы в соответствии с определенными условиями. Обычно системы трансформационной адаптации содержат фиксированное множество операторов адаптации и трансформационных правил.

В задачах выбора схемы лечения методы адаптации имеют свои существенные особенности, отличающие их от иных применений этого подхода.

Авторами настоящей работы разработан и экспериментально реализован эффективный метод адаптации, который описан здесь на примере диагностики и лечения пациентов с болью в спине. Начнем с изложения принципиальных особенностей метода.

Они состоят в том, что если существуют различающиеся прецеденты лечения некоторой нозологической формы конкретных больных (больной X и больной Y), то для поиска схемы лечения другого больного (больной Z) с аналогичным диагнозом и близким состоянием (в смысле метрики, описанной выше), следует выполнить следующие адаптационные действия:

А) на основе схемы лечения пациентов X, и Y построить общую схему лечения данной нозологической формы всех больных с близкими (в смысле введенной метрики) состояниями (действие абстрагирования);

Б) взяв за основу, построенную абстрактную схему (п. А)), и используя персональные особенности больного Z, влияющие на выбор лечебных мероприятий, построить схему лечения больного Z (действие конкретизации).

Для выполнения действия абстрагирования следует удалить из схем лечения пациентов X и Y все особенности их состояний, влияющие на выбор лечебных мероприятий в точках возможного ветвления схемы лечения. В результате будет получена общая схема лечения всех

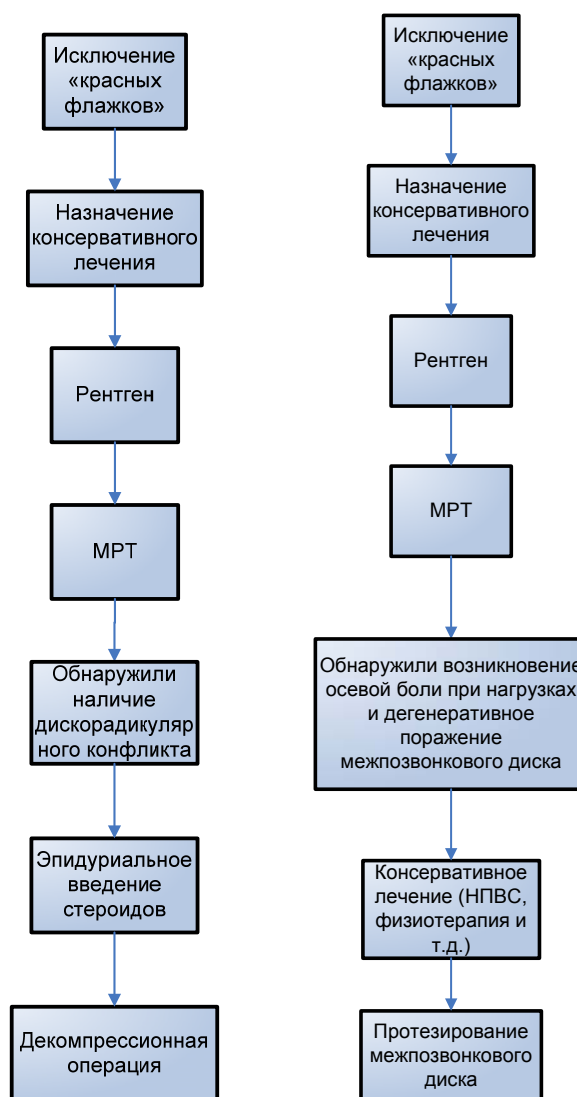


Рис. 1.

Рис. 2.

больных с близкими состояниями для данной нозологической формы.

Например, пусть прецедент схемы лечения пациента X имеет вид, показанный на Рис. 1, а прецедент схемы лечения пациента Y – на Рис. 2.

Более детально особенности схем такого рода описаны в [20].

Выполнив адаптационное действие абстрагирования, т.е. удалив в возможных точках ветвления индивидуальные особенности пациентов X и Y, а именно:

- особенности состояния пациента X:
 - боль в поясничном отделе позвоночника;
 - наличие дискорадикального конфликта;

- особенности состояния пациента Y:
 - боль в поясничном отделе позвоночника;
 - возникновение осевой боли при нагрузках;
 - дегенеративное поражение межпозвонкового диска,

получим общую схему алгоритма диагностики и лечения пациентов с болью в спине группы пациентов с близкими состояниями (Рис.3).

Следует обратить внимание на ветвление схемы лечения в зависимости от индивидуальных особенностей пациентов.

Взяв теперь за основу эту схему и учитывая персональные особенности пациента Z, а именно:

- боль в поясничном отделе позвоночника;
 - наличие дискорadiaкулярного конфликта;
 - боль более шести недель;
 - затруднения при мочеиспускании,
- получим схему лечения пациента Z (Рис.4).

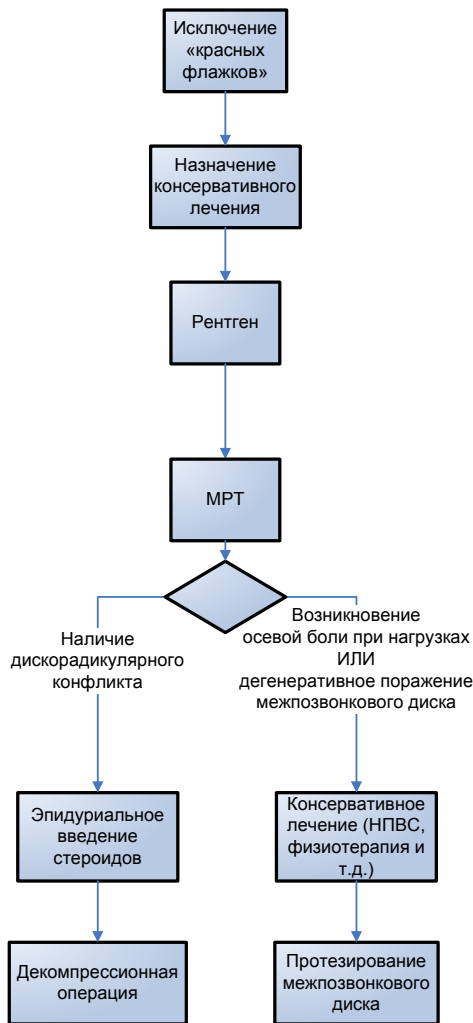


Рис.3.

Как легко видеть, на схеме (Рис.4), в отличие от схемы (Рис.3), отсутствует ветвление. Произошло это в результате учета индивидуальных особенностей пациента Z, приведенных выше.

Разумеется, речь должна идти об учете не двух, а значительно большего числа прецедентов при выполнении абстрагирования. Однако в настоящей работе из соображений простоты был рассмотрен пример абстрагирования на основе двух прецедентов.

Заключение

В настоящей работе рассмотрены теоретические основы построения медицинских экспертных систем, в которых в качестве основного способа представления медицинских знаний выступают системы правил. Рассмотрен на примере метод автоматического обнаружения

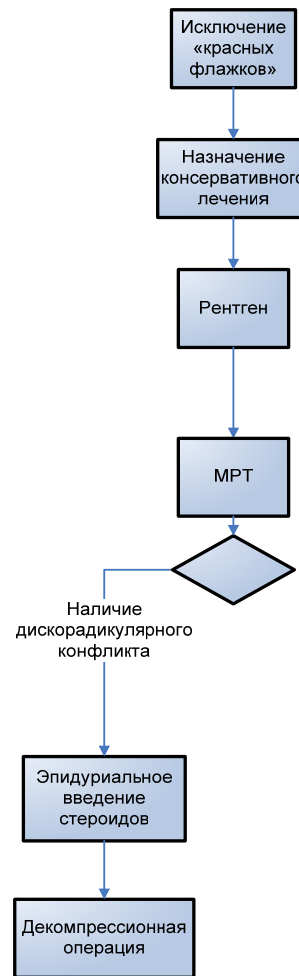


Рис.4.

правил на основе обучения прецедентам. Описан предложенный авторами метод построения плана лечения, основанный на поиске и адаптации прецедентов. Следует отметить перспективность применения в различных медицинских задачах как методов, основанных на непосредственном использовании прецедентов, так и методов обучения на основе прецедентов. Существуют также веские соображения в пользу того, что индуктивные методы обучения способны не только порождать правила (или иные зависимости), явно представляющие знания, содержащиеся в примерах и прецедентах имплицитным образом, но и способствовать обнаружению причин тех или иных заболеваний или патологий.

Литература

- Lindsay, Robert K., Bruce G. Buchanan, E. A. Feigenbaum, and Joshua Lederberg. DENDRAL: A Case Study of the First Expert System for Scientific Hypothesis Formation. *Artificial Intelligence* 61, 2 (1993): 209-261.
- E. H. Shortliffe. *Computer-Based Medical Consultations: MYCIN*. Elsevier/North Holland, New York NY, 1976.
- <http://www.casnet.com>
- <http://dxplain.org/dxp/dxp.pl>
- Barnett GO, Cimino JJ, Hupp JA, Hoffer EP. DXplain - an evolving diagnostic decision-support system. *JAMA*. 1987; 258: 67-74.
- Doherty J, Noiro LA, Mayfield J, Ramiah S, Huang C, Dunagan WC, Bailey TC. Implementing GermWatcher, an enterprise infection control application. *AMIA Annu Symp Proc*.2006:209-13.
- Glenn Edwards, Paul Compton, Ron Malor, Ashwin Srinivasan, Leslie Lazarus. Peirs: A pathologist-maintained expert system for the interpretation of chemical pathology reports. *Pathology*. 1993, Vol. 25, No.1, Pages 27-34
- Aikins JS, Kunz JC, Shortliffe EH, Fallat RJ. PUFF: an expert system for interpretation of pulmonary function data. *Comput Biomed Res*. 1983 Jun;16(3):199-208.
- Кобринский Б.А. Автоматизированные диагностические и информационно-аналитические системы в педиатрии//Русский медицинский журнал. – 1999. т. 7. - №4. с. 35-42.
- Бураковский В.И., Бокерия Л.А., Газизова Д.Ш., Лишук В.А. и др. Компьютерная технология интенсивного лечения: контроль, анализ, диагностика, лечение, обучение. – М.: НЦ ССХ РАМН, 1995.
- Gardner RM, Pryor TA, Warner HR. The HELP hospital information system: update 1998. *Int J Med Inf*. 1999 Jun;54(3):169-82.
- Darmoni SJ, Massari P, Droy JM, Mahe N, Blanc T, Moiro E, Leroy J. SETH: an expert system for the management on acute drug poisoning in adults. *Comput Methods Programs Biomed*. 1994 Jun;43(3-4):171-6
- Fikes R.E., Nilsson N.J. STRIPS: a new approach to application of theorem proving to problem solving. *Artificial Intelligence* 1971, 2.
- Нилсон Н. Принципы искусственного интеллекта. М. МИР, 1977
- Гаврилова Т.А., Червинская К.Н. Извлечение и структурирование знаний для экспертных систем. М.: Радио и связь, 1992.
- Ларичев О.И., Мечитов А.И., Мошкович Е.И., Фуремс Е.М. Выявление экспертных знаний. М.: Наука, 1989, 128 стр.
- Г.С.Осипов. Приобретение знаний интеллектуальными системами. Основы теории и технологии. М.: НАУКА, Физматлит, 1997, 112 стр.
- Miroslav Kubat, Ivan Bratko, Ryszard Michalsky. A Review of Machine Learning Methods. *Machine Learning and Data Mining. Methods and Applications*. 1996, John Wiley&Sons Ltd.
- Назаренко Г.И., Осипов Г.С. Основы теории медицинских технологических процессов. М.: Наука, Физматлит, 2005.
- Назаренко Г.И., Осипов Г.С. Основы теории медицинских технологических процессов. Ч.2. Исследование медицинских технологических процессов на основе интеллектуального анализа данных. М.: Наука, Физматлит, 2006.

Назаренко Герасим Игоревич. Директор Медицинского центра Банка России. Доктор медицинских наук, академик. Автор более 300 работ. Область научных интересов: методы системного анализа и информационные технологии в клинической медицине, медицина катастроф, методы динамического медицинского прогнозирования, автор нового направления в медицине – кваллиметрии травм.

Осипов Геннадий Семенович. Заместитель директора по научной работе Института системного анализа РАН. Доктор физико-математических наук, профессор. Автор 130 работ. Область научных интересов: методы приобретения и представления знаний, методы моделирования поведения, компьютерная лингвистика, поиск в локальных и глобальных сетях, методы искусственного интеллекта в клинической медицине. E-mail: gos@isa.ru

Назаренко Антон Герасимович. Научный сотрудник НИИ Нейрохирургии им. академика Н.Н. Бурденко Окончил ММА им. И.М. Сеченова в 2000 году. Кандидат медицинских наук. Область научных интересов – вертебрология, нейрохирургия, базы знаний, экспертные системы.

Молодченков Алексей Игоревич. Инженер-исследователь Института системного анализа РАН. Окончил Университет города Переславля в 2005 году. Имеет 14 печатных работ. Область научных интересов - искусственный интеллект. E-mail: aim@isa.ru.