

тотную селекцию сигнала рентгеновского датчика, можно реализовать управление глубиной проплавления при ЭЛС.

Проведенные исследования позволяют сделать следующие выводы.

1. При наличии периодических составляющих в некоторых параметрах проникающего рентгеновского излучения выходной сигнал датчика рентгеновского излучения представляет собой «почти» периодический процесс, составляющие которого находятся в определенном соответствии с уровнем фокусировки электронного луча и глубиной проплавления.

2. Осуществляя частотную селекцию сигнала датчика проникающего рентгеновского излучения, можно осуществлять управление уровнем фокусировки электронного луча и глубиной проплавления.

#### Библиографические ссылки

1. Устройство управления фокусировкой и глубиной проплавления по собственному рентгеновскому излучению при ЭЛС с модуляцией уровня фокусировки / В. Я. Браверман, С. Г. Баякин, В. В. Башенко, В. Ф. Шабанов // Сварочное производство. 1997. № 1. С. 16–19.
2. Пат. РФ № 2113954. Способ электронно-лучевой сварки / В. Я. Браверман, С. Г. Баякин, В. В. Башенко, В. Ф. Шабанов. 1998. Бюл. № 12.
3. Бендат Дж., Пирсол А. Измерение и анализ случайных процессов : пер. с англ. М. : Мир, 1971.
4. Hablani M. H. A correlation of welding variables // Proc. Forth Symp. Electron Beam Technol., Boston, March 1962 / ed. R. Bakish. Boston, 1962.
5. Башенко В. В. Электронно-лучевые установки. Л. : Машиностроение, 1975.

V. Ya. Braverman, V. S. Belozertsev

### FREQUENCY-DOMAIN METHOD OF ESTIMATION OF ELECTRON BEAM FOCUSING LEVEL AND MELTING DEPTH DURING ELECTRON-BEAM WELDING

*The article considers possibility of obtaining of determinate spectrum of output signal of penetrating X-ray radiation sensor to control focusing level and melting depth during electron-beam welding.*

*Keywords: electron beam welding, x-ray radiation, melting depth, electron beam focusing level.*

© Браверман В. Я., Белозерцев В. С., 2010

УДК 519.854.33

С. Е. Головенкин, Т. К. Гулакова, Р. И. Кузьмич, И. С. Масич, В. А. Шулман

### МОДЕЛЬ ЛОГИЧЕСКОГО АНАЛИЗА ДЛЯ РЕШЕНИЯ ЗАДАЧИ ПРОГНОЗИРОВАНИЯ ОСЛОЖНЕНИЙ ИНФАРКТА МИОКАРДА\*

*Исследуется метод классификации данных, основанный на поиске и использовании логических правил. Решающее правило классификации базируется на модели, получаемой в результате решения ряда задач комбинаторной оптимизации. Строится модель классификации для прогнозирования осложнений инфаркта миокарда.*

*Ключевые слова: инфаркт миокарда, классификация, комбинаторная оптимизация, логические алгоритмы, прогнозирование.*

Большое количество задач распознавания, привлекающих внимание исследователей как в медицине, так и во множестве других областей, может быть сформулировано следующим образом. Имеется выборка данных, которая состоит из двух непересекающихся множеств  $\Omega^+$  и  $\Omega^-$   $n$ -мерных векторов. Каждый вектор соответствует некоторому пациенту, векторы множества  $\Omega^+$  соответствуют пациентам, находящимся в некотором медицинском состоянии (например, болен или имеет осложнение заболевания), а векторы  $\Omega^-$  не соответствуют этому состоянию. Компоненты векторов (называемые признаками,

переменными, характеристиками или атрибутами) представляют собой результаты определенных измерений, тестов или просто показывают присутствие или отсутствие определенных симптомов. Эти компоненты могут быть численными, номинальными или бинарными.

Задача состоит в том, чтобы на основании имеющейся выборки данных (классифицированных ранее наблюдений) извлечь информацию о состоянии «нового» пациента, наблюдение которого не содержится в выборке. Главная цель решения таких задач – на основе анализа данных и вычислительных систем диагностики и прогно-

\* Работа выполнена при финансовой поддержке гранта Президента РФ (код проекта МК-463.2010.9).

зирования определить индивидуальную терапию для пациента.

Для решения этой задачи исследуется метод анализа данных, в основе которого лежит принцип вывода логических закономерностей, или правил. Каждое правило должно покрывать достаточно много объектов одного класса и практически не покрывать объекты другого класса. Взяв вместе некоторое количество правил, можно получить алгоритм (модель, решающее правило), который будет решать поставленную задачу классификации. Главной особенностью использования такого подхода является то, что в результате работы метода из базы данных извлекаются правила, с помощью которых можно классифицировать объекты и без помощи компьютера и вычислительной системы.

**Осложнения инфаркта миокарда.** Инфаркт миокарда (ИМ) – распространенное и грозное заболевание. Бурное распространение этого заболевания за последние полвека сделало его одной из наиболее острых проблем современной медицины. Несмотря на то что внедрение современных лечебно-профилактических мероприятий несколько снизило смертность от инфарктов, она продолжает оставаться довольно высокой.

Течение заболевания у пациентов с ИМ различно. ИМ может протекать без осложнений или с осложнениями, не ухудшающими долгосрочный прогноз. В то же время около половины пациентов в острый и подострый периоды имеют осложнения, приводящие к ухудшению течения заболевания и даже летальному исходу. Предвидеть развитие этих осложнений не всегда может даже опытный специалист. В связи с этим прогнозирование осложнений ИМ с целью своевременного проведения необходимых профилактических мероприятий представляется актуальной задачей.

В исследование включены 1 700 больных острым инфарктом миокарда, проходивших лечение в отделении реанимации и интенсивной терапии и в кардиологическом отделении городской клинической больницы [1]. Информация об анамнезе пациентов и течении ИМ получена из историй болезни и сконцентрирована в 117 полях электронной таблицы (базы данных). База данных содержит информацию о возрасте, поле пациента, локализации и глубине ИМ, данных анамнеза, изменениях ЭКГ, количестве калия, натрия, некоторых ферментов крови, особенностях клиники в первые часы заболевания.

За период пребывания больных в стационаре фибрилляция предсердий (ФП) наблюдалась у 170 (10,0 %) больных, фибрилляция желудочков (ФЖ) у 71 (4,2 %), отек легких (ОЛ) у 159 (9,4 %), разрыв сердца (РС) у 54 (3,2 %), летальный исход (ЛИ) у 271 (15,9 %). Данные осложнения и ЛИ были выбраны для прогнозирования.

Ранее для прогнозирования коллективом ученых [1] была создана экспертная система на основе искусственных нейронных сетей. В результате настройки алгоритма обучения и параметров сети на данной выборке была достигнута точность прогнозирования 70...90 %.

**Логический анализ данных.** В основе предлагаемого подхода к классификации данных лежит метод, происходящий из теории комбинаторной оптимизации и называемый логическим анализом данных (Logical Analysis of Data – LAD) [2]. Последовательные элементы метода:

1) для исключения избыточных переменных в исходной выборке данных в множестве переменных определяется некоторое подмножество  $S$ , используя которое, можно отличать положительные наблюдения от отрицательных. Далее для работы метода используются проекции  $\Omega_s^+$  и  $\Omega_s^-$  множеств  $\Omega^+$  и  $\Omega^-$  на  $S$ ;

2) множество  $\Omega_s^+$  покрывается семейством однотипных подмножеств уменьшенного пространства, каждое из которых имеет значительное пересечение с  $\Omega_s^+$ , но не пересекается с  $\Omega_s^-$ . Такие подмножества назовем «положительными паттернами». Аналогично множество  $\Omega_s^-$  покрывается «отрицательными паттернами»;

3) определяется подмножество положительных паттернов, объединение которых покрывает все наблюдения  $\Omega_s^+$ , и подмножество отрицательных паттернов, объединение которых покрывает все наблюдения  $\Omega_s^-$ ;

4) положительный или отрицательный характер некоторого наблюдения, покрываемого объединением двух подмножеств модели, определяется с помощью решающего правила, основанного на этих подмножествах.

Отличительной особенностью предлагаемого метода является то, что вместо того чтобы просто ответить на вопрос, к какому из классов принадлежит новое наблюдение, он строит аппроксимацию областей пространства признаков, содержащую наблюдения соответствующих классов. Наиболее важные преимущества такого подхода – это возможность дать объяснение для любого решения, полученного данным методом, возможность выявления новых классов наблюдений, возможность анализа роли и природы признаков.

**Модель классификации.** В основе рассматриваемого подхода лежит понятие паттерна. Положительным паттерном называется подкуб пространства булевых переменных  $B_2^t$ , который пересекается с множеством  $\Omega_s^+$  и не имеет общих элементов с множеством  $\Omega_s^-$ . Отрицательный паттерн задается аналогично. Положительный  $\omega$ -паттерн для  $\omega \in \{0, 1\}^t$  – это паттерн, содержащий в себе точку  $\omega$ . Для каждой точки  $\omega \in \Omega_s^+$  найдем максимальный  $\omega$ -паттерн, т. е. покрывающий наибольшее число точек  $\Omega_s^+$ .

Соответствующий подкуб зададим с помощью переменных  $y_j$ :

$$y_j = \begin{cases} 1, & \text{если } x_j \text{ зафиксирована в подкубе,} \\ 0, & \text{в противном случае.} \end{cases}$$

Иными словами, путем фиксирования  $l$  переменных исходного куба размерностью  $t$  получаем подкуб размерностью  $(t-l)$  и с числом точек  $2^{t-l}$ .

Условие, говорящее о том, что положительный паттерн не должен содержать ни одной точки  $\Omega_s^-$ , требует, чтобы для каждого наблюдения  $\rho \in \Omega_s^-$  переменная  $y_j$  принимала значение 1 по меньшей мере для одного  $j$ , для которых  $\rho_j \neq \omega_j$ :

$$\sum_{\substack{j=1 \\ \rho_j \neq \omega_j}}^t y_j \geq 1 \text{ для любого } \rho \in \Omega_s^-.$$

Усиление ограничения для повышения устойчивости к ошибкам производится путем замены числа 1 в правой части неравенства на целое положительное число  $d$ .

С другой стороны, позитивное наблюдение  $\sigma \in \Omega_s^+$  будет тогда входить в рассматриваемый подкуб, когда пе-

ременная  $y_j$  принимает значение 0 для всех индексов  $j$ , для которых  $\sigma_j \neq \omega_j$ . Таким образом, число положительных наблюдений, покрываемых  $\omega$ -паттерном, может быть вычислено как

$$\sum_{\sigma \in \Omega_S^+} \prod_{\substack{j=1 \\ \sigma_j \neq \omega_j}}^t (1 - y_j).$$

Таким образом, имеем задачу условной псевдодобулевой оптимизации с алгоритмически заданными функциями:

$$\sum_{\sigma \in \Omega_S^+} \prod_{\substack{j=1 \\ \sigma_j \neq \omega_j}}^t (1 - y_j) \rightarrow \max, \quad (1)$$

$$\sum_{\substack{j=1 \\ \rho_j \neq \omega_j}}^t y_j \geq d \text{ для любого } \rho \in \Omega_S^-, y \in \{0, 1\}^t. \quad (2)$$

Аналогично формулируется задача нахождения максимальных отрицательных паттернов.

В итоге получаем семейство максимальных паттернов, число которых ограничено мощностью выборки данных  $|\Omega^+ \cup \Omega^-|$ . Обозначим  $M_1^+, \dots, M_p^+$  и  $M_1^-, \dots, M_q^-$  соответственно множества положительных и отрицательных паттернов.

Чтобы классифицировать новое наблюдение, воспользуемся следующим решающим правилом:

1) если наблюдение удовлетворяет условиям одного или нескольких положительных паттернов и не удовлетворяет условиям ни одного из отрицательных, то оно классифицируется как положительное;

2) если наблюдение удовлетворяет условиям одного или нескольких отрицательных паттернов и не удовлетворяет условиям ни одного из положительных, то оно классифицируется как отрицательное;

3) если наблюдение удовлетворяет условиям  $p'$  из  $p$  положительных паттернов и  $q'$  из  $q$  отрицательных, то «знак» наблюдения определяется как  $(p'/p - q'/q)$ ;

4) в случае если наблюдение не удовлетворяет условиям ни одного паттерна, положительного или отрицательного, то оно остается неклассифицированным.

Найденный паттерн характеризуется покрытием – числом объектов определенного класса, которые он захватывает, и степенью – количеством фиксированных переменных, которые определяют этот паттерн. Согласно приведенной выше оптимизационной модели (1)–(2), паттерн не покрывает ни одного объекта другого класса (из обучающей выборки).

Наибольшую ценность представляют паттерны, которые имеют наибольшее покрытие. Чем больше покрытие, тем лучше паттерн отображает образ класса.

Специфика описанной выше задачи прогнозирования состоит в том, что база данных имеет большое число неизмеренных значений (пропущенных данных), а сделанные измерения могут быть неточны либо ошибочны. Шумы и выбросы приводят к тому, что объекты различных классов «накладываются» друг на друга, попадая в «область» противоположного класса. В результате вычисляемые паттерны получают с большей степенью и с существенно меньшим покрытием, чем если бы выбросов и неточностей не было, а итоговая модель состоит из большого числа маленьких паттернов (с малым по-

крытием). Это не позволяет построить эффективную модель классификации с «хорошо интерпретируемыми» правилами (в которых участвует небольшое число признаков) и с высокой точностью распознавания.

Для повышения устойчивости метода к выбросам следует ослабить ограничение (2). Тогда степень вычисляемых паттернов уменьшится, а покрытие увеличится.

Ограничение оптимизационной модели будет выглядеть следующим образом:

$$\sum_{\rho \in \Omega_S^-} z_\rho \leq D, \text{ где } z_\rho = \begin{cases} 0, & \text{если } \sum_{\substack{j=1 \\ \rho_j \neq \omega_j}}^t y_j \geq d, \\ 1, & \text{в противном случае;} \end{cases} \quad (3)$$

где  $D$  – число объектов другого класса, которые допускаются быть покрытыми паттерном (целое неотрицательное число).

Функции (1)–(3) построенной модели оптимизации задаются алгоритмически, т. е. вычисляются через определенную последовательность операций. Для решения задачи оптимизации использовались алгоритмы оптимизации, основанные на поиске граничных точек допустимой области. Эти алгоритмы были разработаны специально для этого класса задач и основаны на поведении монотонных функций модели оптимизации в пространстве булевых переменных. Алгоритмы поиска граничных точек являются поисковыми, т. е. не требуют задания функций в явном виде, с помощью алгебраических выражений, а используют вычисления функций в точках.

**Результаты экспериментов.** Описанная выше задача по прогнозированию осложнений заболевания решалась с помощью разработанного алгоритма. Исходными данными является выборка, состоящая из 1 700 объектов, каждый из которых характеризуется 117 признаками. Среди признаков встречаются как бинарные (большая часть) и номинальные, так и численные признаки. В выборке присутствует значительное число пропущенных данных.

Ввиду довольно большого объема исходных данных, первоначально для проведения многочисленных серий экспериментов за приемлемое время были использованы уменьшенные выборки. Для каждой из пяти решаемых задач формировались свои выборки данных. При этом в выборку включались все положительные объекты по конкретной задаче (прогнозируемому осложнению), так как их изначально представлено значительно меньше, а отрицательные объекты (без этого осложнения) выбирались из первичной выборки случайным образом.

Для нахождения правил использовались две оптимизационные модели: «жесткая» модель, не допускающая, чтобы построенные правила покрывали объекты другого класса; и модифицированная модель, позволяющая, чтобы правила покрывали некоторое ограниченное число объектов другого класса для «смягчения» возможных неточностей и ошибок в данных.

Следует сделать важное замечание по точности полученных результатов. Точность классификации определяется двумя значениями: чувствительностью – точностью определения пациентов с осложнением, и специфичностью – точностью определения пациентов без осложнений. На практике к чувствительности предъявляются боль-

шие требования, чем к специфичности. Используемый алгоритм (и, соответственно, программное приложение) позволяет повышать чувствительность за счет специфичности (и наоборот) путем изменения весов в решающем правиле. В таблицах приведены точности без каких-либо поправок коэффициентов в решающей функции, т. е. так, как описано выше.

К одному из наиболее важных результатов относится то, что построенная модель классификации, состоящая из набора отдельных правил, позволяет оценить значимость признаков. Чем чаще признак встречается в модели, тем он более значим. А те признаки, которые не встречаются или почти не участвуют в построении решающей модели, значимыми не являются. Как показывают проведенные эксперименты, исключение таких признаков из выборки при построении правил классификации ведет к улучшению решающей модели. Модель, построенная на уменьшенном множестве признаков, как правило, оказывается более точной.

Ниже приведены результаты экспериментов по решению пяти задач прогнозирования.

*Задача 1. Фибрилляция предсердий.* Для проведения испытаний использовалась выборка данных, состоящая из 169 пациентов с осложнением (положительные объекты) и 169 объектов без осложнения (отрицательные объекты). 10 % из них использовались для контроля и в построении решающей модели не участвовали.

В результате бинаризации из 112 признаков было получено 214 бинарных признаков.

Рассмотрим результаты испытаний с использованием двух оптимизационных моделей: с ограничением (2), исключающим захват паттерном объекта другого класса, и с ограничением (3), позволяющим покрытие паттерном нескольких объектов другого класса (табл. 1). Приведены средние значения покрытий и степени для наборов паттернов.

В результате экспериментов выявлено 7 важных признаков при построении положительных паттернов и 6 при построении отрицательных паттернов. Также был выявлен набор из 36 признаков, не принимающих участие при построении паттернов.

Также задача решалась на уменьшенном множестве признаков, полученном путем исключения незначимых признаков (табл. 2).

В результате бинаризации из 76 признаков было получено 179 бинарных признаков.

*Задача 2. Фибрилляция желудочков.* В испытании участвовали по 70 положительных и отрицательных объектов, 15 % использовалось при тесте.

Бинарных признаков 206 из 112 исходных.

Результаты представлены в табл. 3.

При построении положительных паттернов выявлено 4 важных признака, при построении отрицательных паттернов – 4 важных признака, а также 56 признаков, не принимающих участие при построении паттернов. Результат исследования при участии 56 признаков (145 бинарных) представлен в табл. 4.

*Задача 3. Разрыв сердца.* В испытании участвовало по 54 положительных и отрицательных объектов, 15 % использовались для тестирования. Бинарных признаков 204. Результаты для двух моделей представлены в табл. 5.

При построении положительных паттернов выявлено 5 важных признаков, при построении отрицательных паттернов – 5 важных признаков, а также 61 признак, не принимающий участие при построении паттернов. Результат исследования при участии 51 признака (139 бинарных) представлен в табл. 6

*Задача 4. Отек легких.* В испытании участвовало 157 положительных и 181 отрицательных объектов, 10 % использовались для тестирования. Бинарных признаков 212. Результаты для двух моделей представлены в табл. 7.

Таблица 1

Задача оптимизации	Множество паттернов	Покрытие отрицательных объектов	Покрытие положительных объектов	Степень паттерна	Точность классификации, %
Целевая функция (1), ограничение (2)	Отрицательные	13	0	5	84
	Положительные	0	13	7	87
Целевая функция (1), ограничение (3)	Отрицательные	23	3	5	89
	Положительные	3	23	7	100

Таблица 2

Задача оптимизации	Множество паттернов	Покрытие отрицательных объектов	Покрытие положительных объектов	Степень паттерна	Точность классификации, %
Целевая функция (1), ограничение (2)	Отрицательные	14	0	5	79
	Положительные	0	13	7	93
Целевая функция (1), ограничение (3)	Отрицательные	21	3	5	79
	Положительные	3	23	7	87

Таблица 3

Задача оптимизации	Множество паттернов	Покрытие отрицательных объектов	Покрытие положительных объектов	Степень паттерна	Точность классификации, %
Целевая функция (1), ограничение (2)	Отрицательные	15	0	6	100
	Положительные	0	14	6	86
Целевая функция (1), ограничение (3)	Отрицательные	26	3	3	92
	Положительные	3	21	5	100

При построении положительных паттернов выявлено 8 важных признаков, при построении отрицательных паттернов – 3 важных признака, а также 12 признаков, не принимающих участие при построении паттернов. Результат исследования при участии 100 признаков (201 бинарных) представлен в табл. 8.

*Задача 5. Летальный исход.* В испытании участвовали 160 положительных и 160 отрицательных объектов, 10% использовались для тестирования. Бинарных признаков 214. Результаты для двух моделей представлены в табл. 9.

При построении положительных паттернов выявлено 11 важных признаков, при построении отрицательных паттернов – 5 важных признаков, а также 59 признаков, не принимающих участие при построении паттернов. Результат исследования при участии 63 признаков (163 бинарных) представлен в табл. 10.

Результаты проведенных экспериментов позволяют сделать следующие выводы.

Во-первых, модификация условий при поиске правил позволяет находить паттерны с более высоким покрытием, из которых строится более точная модель распознавания. Применение такого подхода необходимо при решении задач с наличием выбросов и шумов и с большим количеством пропусков в выборке данных.

Во-вторых, помимо самого прогнозирования, для каждой задачи оценена значимость признаков. Уменьшение множества признаков за счет исключения незначимых признаков ведет к улучшению решения задачи.

В целом, задача прогнозирования осложнений инфаркта миокарда решена с точностью, сопоставимой с точностью решения посредством искусственных нейронных сетей. При этом логический анализ данных дает ряд преимуществ при практическом использовании. Прежде всего, в явном виде известны правила, по которым принимается решение о принадлежности к какому-либо классу. Кроме того, при применении модели классификации к

Таблица 4

Задача оптимизации	Множество паттернов	Покрытие отрицательных объектов	Покрытие положительных объектов	Степень паттерна	Точность классификации, %
Целевая функция (1), ограничение (2)	Отрицательные	16	0	3	100
	Положительные	0	14	5	92
Целевая функция (1), ограничение (3)	Отрицательные	27	3	2	89
	Положительные	3	22	6	100

Таблица 5

Задача оптимизации	Множество паттернов	Покрытие отрицательных объектов	Покрытие положительных объектов	Степень паттерна	Точность классификации, %
Целевая функция (1), ограничение (2)	Отрицательные	19	0	3	67
	Положительные	0	17	5	100
Целевая функция (1), ограничение (3)	Отрицательные	24	3	3	100
	Положительные	3	26	4	62

Таблица 6

Задача оптимизации	Множество паттернов	Покрытие отрицательных объектов	Покрытие положительных объектов	Степень паттерна	Точность классификации, %
Целевая функция (1), ограничение (2)	Отрицательные	13	0	3	100
	Положительные	0	19	5	75
Целевая функция (1), ограничение (3)	Отрицательные	23	3	3	100
	Положительные	3	28	5	75

Таблица 7

Задача оптимизации	Множество паттернов	Покрытие отрицательных объектов	Покрытие положительных объектов	Степень паттерна	Точность классификации, %
Целевая функция (1), ограничение (2)	Отрицательные	14	0	4	76
	Положительные	0	20	7	65
Целевая функция (1), ограничение (3)	Отрицательные	22	3	5	65
	Положительные	3	35	7	82

Таблица 8

Задача оптимизации	Множество паттернов	Покрытие отрицательных объектов	Покрытие положительных объектов	Степень паттерна	Точность классификации, %
Целевая функция (1), ограничение (2)	Отрицательные	14	0	5	100
	Положительные	0	36	7	95
Целевая функция (1), ограничение (3)	Отрицательные	23	3	5	86
	Положительные	3	35	8	70

новому пациенту по тому, каким числом паттернов покрываются его данные, можно судить о вероятности возможной ошибки при распознавании.

#### Библиографические ссылки

1. Осложнения инфаркта миокарда: база данных для апробации систем распознавания и прогноза : препринт № 6 / А. Н. Горбань, В. А. Шульман, Д. А. Россиев и др. ; Вычислит. центр СО РАН. Красноярск, 1997.
2. Hammer, P. L., Bonates T. Logical Analysis of Data: From Combinatorial Optimization to Medical Applications : research report 10-2005 / RUTCOR. N. Y., 2005.

Таблица 9

Задача оптимизации	Множество паттернов	Покрытие отрицательных объектов	Покрытие положительных объектов	Степень паттерна	Точность классификации, %
Целевая функция (1), ограничение (2)	Отрицательные	14	0	4	50
	Положительные	0	33	7	88
Целевая функция (1), ограничение (3)	Отрицательные	22	3	4	75
	Положительные	3	52	7	88

Таблица 10

Задача оптимизации	Множество паттернов	Покрытие отрицательных объектов	Покрытие положительных объектов	Степень паттерна	Точность классификации, %
Целевая функция (1), ограничение (2)	Отрицательные	13	0	4	81
	Положительные	0	30	7	88
Целевая функция (1), ограничение (3)	Отрицательные	21	3	4	81
	Положительные	3	47	7	88

S. E. Golovenkin, T. K. Gulakova, R. I. Kuzmich, I. S. Masich, V. A. Shulman

### MODEL OF LOGICAL ANALYSIS FOR SOLVING PROBLEM OF PROGNOSIS OF MYOCARDIAL INFARCTION COMPLICATIONS

*A data classification method based on search and usage of logical rules is considered in the paper. The decision rule is based on the model received as a result of solving combinatorial optimization problems. The classification model for prediction of myocardial infarction complications is constructed.*

*Keywords: myocardial infarction, classification, combinatorial optimization, logical algorithms, prognosis.*

© Головенкин С. Е., Гулакова Т. К., Кузьмич Р. И., Масич И. С., Шульман В. А., 2010