

УДК 519.1

ВОПРОСЫ АНАЛИЗА И РАСПОЗНАВАНИЯ МОЛЕКУЛЯРНЫХ  
СТРУКТУР НА ОСНОВЕ ОБЩИХ ФРАГМЕНТОВ

Н.Г.Загоруйко, В.А.Скоробогатов, П.В.Хворостов

Известное направление химических исследований, посвященных изучению зависимости между химическими или биологическими свойствами веществ и их строением, интенсивно развивается [1,2]. Эти исследования затрагивают различные аспекты, например, в [3] изучаются зависимости физико-химических параметров многоатомных молекул углеводородов от структуры взаимного расположения атомов и их связей. Одним из важнейших является вопрос о связи биологической активности соединений и их химического строения, в частности, для лекарственных препаратов. Впервые этот вопрос возник в середине 19 века. Позже было установлено, что всякое изменение в структуре молекулы органического вещества изменяет в ту или иную сторону характер его действия на живой организм. Более общее предположение, которое подтверждается экспериментально, состоит в том, что сходные по структуре соединения должны оказывать сходные воздействия. Подходы к определению структурного сходства или подобия различны. Для этих целей можно использовать любые конструктивно выражаемые свойства структур, такие, например, как метрические, конформационные, циклические или другие топологические свойства. Традиционно подобие строения соединений определяется через наличие в молекулах определенных структурных фрагментов. Фрагменты могут состоять из функциональных групп или каких-то других частей молекул, которые возникли на основе привычных классификационных признаков химических классов.

По мере роста сложности новых соединений и их проявлений возникают нетрадиционные ситуации, когда объективный выбор классификационных фрагментов становится затруднительным, поскольку

обнаружить достаточно сложные (крупные) фрагменты в большом количестве структур невозможно. Тогда либо фрагменты неоправданно упрощаются, т.е. теряется информация о возможном наличии общих структурных свойств в данном множестве соединений, либо они выбираются субъективно с целью проверки при последующей классификации структур на обучающих выборках. В этом случае успех при выборе подходящей системы фрагментов существенно зависит от объема вычислительной работы, в основе которой лежит перебор большого числа всевозможных подходящих фрагментов.

Наличие эффективной машинной методики нахождения достаточно полных систем структурных фрагментов для реальных классов соединений позволит получать объективно существующие признаки подобия и, следовательно, получать более объективные решения.

Результат выбора систем фрагментов зависит еще и от степени детальности описания структур: можно описывать молекулы с точностью до отдельных атомов, т.е. во входном описании структуры каждый атом кодировать отдельно. В этом случае анализ структур может быть осуществлен наиболее детально. Но и сложность такого анализа существенно возрастет, так как увеличивается размерность комбинаторных задач, которые лежат в основе такого анализа. По-видимому, для определенных приложений должна подбираться необходимая степень детализации описания молекулярных структур. Так, например, при исследовании активности лекарственных препаратов [2] используются так называемые фармакофоры – небольшие структурные фрагменты, состоящие из определенным образом соединенных атомов. Установление структурного подобия в указанных задачах может проводиться с точностью до фармакофоров.

При исследовании других видов активности, по-видимому, также могут быть определены группы атомов, аналогичные фармакофорам.

В [4] приводятся требования к системам признаков. Признаки должны порождаться автоматически, в результате анализа должен быть ясен их физический смысл и число их должно быть небольшим.

Из последнего требования можно сделать вывод, что признаки должны быть достаточно крупными (в пределе максимально крупными) и, следовательно, информационно емкими.

I. Некоторые функции системы SISTRAN. В данной работе приводится описание алгоритмической системы обработки структурной информации, предназначеннной для поиска признаков структурного подобия молекулярных графов органических соединений. В системе преду-

сматриваются средства для экспериментов по распознаванию и прогнозированию свойств; она может также применяться при топологическом анализе других видов структурной информации.

I.I. Описание и ввод структур. Может проводиться одновременная обработка ряда семейств молекул, описанных на языке ОГРА-30 [5]. Точность описания фиксируется в виде базисного набора меток вершин и связей молекулярных графов. После необходимого контроля и проверки исходной информации путем применения контролирующего модуля информация записывается в память ЭВМ в виде матриц смежности молекулярных графов.

Правила описания на языке ОГРА-30 напоминают правила кодирования Висвессера, однако, в связи с тем, что группы атомов при кодировании на языке ОГРА-30 имеют номера, фактически отдель-




Рис. I

но описываются топология структуры и дополнительно ее нетопологические особенности, в то время как в коде Висвессера [6] топология описывается одновременно и на глядность записи теряется (рис. I).

Код на языке ОГРА-30:  $\text{INH}_2-3-4\text{C}-5\text{OH}$  или  $12-3-4V-5Q$ .

Код Висвессера:  $22VQ$ , где 2-группа  $\text{NH}_2$ , V-группа  $>\text{C}=\text{O}$ , Q-группа —  $\text{OH}$ .

По этой причине ОГРА-30 обладает значительной универсальностью и может быть без переделки приспособлена для описания различных форм структурной информации только изданием соответствующих специальных инструкций по кодированию в данной области применений.

Следует отметить, что как вся представляемая здесь система, так и версия языка ОГРА-30 ориентированы на пакетный режим обработки структурной информации, при котором информация готовится заранее, а не непосредственно при решении задач на ЭВМ в режиме диалога. Такой подход обладает известными недостатками, но не требует уникального оборудования. Ввод структур может быть осуществлен с перфокарт или магнитной ленты, либо с алфавитно-цифрового дисплея.

2. Хранение и поиск структур. Для увеличения гибкости при обработке множества структур, состоящего из отдельных семейств, может возникнуть необходимость изменить отдельные семейства путем их пополнения или замены в них некоторых структур. Для этого необходимо иметь средства идентификации, позволяющие устанавливать

наличие или отсутствие данной структуры в семействе. Эта манипуляция обеспечивается двумя функциями системы: хранением структур в виде линейных канонических кодов на языке ОГРА-30 и канонизацией запрашиваемой структуры с последующим сравнением канонических кодов.

Приведем более подробное описание метода канонизации графов на языке ОГРА-30.

**2.1. Канонизация графов.** При массовом распознавании изоморфизма графов, их хранении и поиске удобно использовать следующий прием. В каждом классе попарно изоморфных графов выбирается один граф, называемый каноническим видом любого графа данного класса. После этого распознавание изоморфизма графов сводится к построению и сравнению канонических видов. Каноническим видом графа называется граф, матрица смежности которого определяется переупорядочиванием вершин в соответствии с их свойствами, не зависящими от исходной нумерации. Нумерацию вершин графа, соответствующую каноническому виду, назовем канонической.

Для построения канонической нумерации вершин помеченного графа  $G(V, X)$ ,  $|V| = p$ , сначала рассматривается упорядоченное разбиение множества  $V$  на классы эквивалентности, совпадающие с орбитами графа:  $V = \{v_1, \dots, v_s\}$ ,  $v_i \cap v_j = \emptyset$ ,  $i \neq j$ . Считаем, что  $v_i > v_j$ , если  $m(v) > m(u)$ ,  $\forall v \in v_i, \forall u \in v_j$ , где  $m: V \rightarrow R^s \subset R$  – однозначная функция, ставящая в соответствие меткам вершин действительные числа. Если  $m(v) = m(u)$ , то  $v_i > v_j$ , в том случае, когда вектор  $D(v) = (d_{v_1}(v), \dots, d_{v_s}(v))$  лексикографически старше вектора  $D(u) = (d_{u_1}(u), \dots, d_{u_s}(u))$ , где  $d_{v_i}$  – число ребер, соединяющих вершину  $v_i$  (или  $u_i$ ) с вершинами из класса  $v_i$ ,  $i = 1, s$ . Для мультиграфа вместо одного числа  $d_{v_i}$  рассматривается набор весов ребер.

Если  $s = p$  (в каждом классе  $v_i$  содержится ровно одна вершина), то полученный порядок вершин является канонической нумерацией.

Если  $s < p$ , то выбираются первый по порядку класс  $v_1$ ,  $|v_1| > 1$ , и некоторая вершина  $v \in v_1$ . К разбиению  $\{v_1, \dots, v_1 \setminus v, \dots, v_s, v\}$  применяется итеративная процедура доразбиения классов в соответствии с векторами  $D[7]$ . Если число полученных классов совпадает с  $p$ , то имеем каноническую нумерацию, иначе снова выбираем  $|v_1| > 1$  и повторяем процесс до тех пор, пока не получим  $s = p$ .

Очевидно, что канонические виды изоморфных графов совпадают.

Для компактного хранения графов в каноническом виде используется запись на языке ОГРА-30, в которой описание графа представ-

лено в виде его покрытия множеством цепей. Каждая цепь формируется следующим образом. Выбирается вершина  $v_1$ , с минимальным каноническим номером и записывается последовательность ребер  $(v_1, v_2), (v_2, v_3), \dots, (v_{i-1}, v_i), \dots$ , где  $v_1$  – вершина с минимальным номером, смежная с  $v_{i-1}$ . После записи ребро помечается. Если вершина




Рис. 2

$v_1$  не имеет непомеченных инцидентных ребер, то цепь заканчивается. Далее выбирается вершина с минимальным номером, имеющая непомеченные инцидентные ребра, и начинается формирование новой цепи. Граф полностью покрыт, когда помечены все ребра.

Например, для графа G на рис.2 будет сформирована запись  $G = 1-8 \text{ N } - 7\text{CO}-6\text{N}-3-2(2) * 4-5\text{CO}-6 * 4-9\text{CO}-8 **$

При формировании записи опускаются метки С, CH, CH<sub>2</sub>, CH<sub>3</sub>, так как они могут быть однозначно восстановлены при учете валентности.

3. Нахождение общих максимальных фрагментов в парах структур. Под общим фрагментом двух структур  $G_1$  и  $G_2$  понимается граф, который изоморден некоторому подграфу из  $G_1$  и некоторому подграфу из  $G_2$ , причем хотя бы один из этих подграфов максимальен, т.е.




Рис. 3

имеет наибольшее число вершин, для которого еще сохраняются указанные свойства. Такой общий фрагмент называют также пересечением двух структур. Так, например, бензол и нитробензол (рис.3) имеют общий фрагмент – бензольное кольцо.

Многие практические задачи обработки структурных данных сводятся к нахождению общих фрагментов. При помощи этой операции можно обеспечить поиск структур, содержащих заданный фрагмент или их набор, что позволяет сформировать множество или ряды похожих структур для дальнейшего анализа. Найдя все попарные пересечения для данного семейства структур и их взаимные вхождения после некоторого дополнительного анализа, можно сформировать набор фрагментов, объективно характеризующих данное семейство. Если решить такую задачу для достаточно представительной выборки, то можно сформировать правило для отнесения неизвестных молекулярных структур к данному химическому классу.

Предусматривается возможность осуществить не попарный, а одновременный поиск общих частей в семействе структур на основе к-местной операции пересечения [8] или путем многократного применения двухместной операции.

4. Задачи распознавания образов. Пусть дана обучающая выборка, состоящая из нескольких семейств структур. Найдем общие признаки-фрагменты (п.3) для каждого из семейств, а также будем использовать информацию о наличии или отсутствии этих признаков в структурах из других семейств. На основе такой информации можно построить решающее правило, позволяющее установить к какому семейству может быть отнесена некоторая новая структура.

Если дано множество структур, о котором предварительно ничего не известно, то можно найти разбиение этого множества на классы, пользуясь понятием подобия, введенного на основе метрики пространства признаков.

4.1. П о д о б и е г р а ф о в . Для определения степени подобия классов изоморфных графов введем понятие расстояния между графиками в метрическом пространстве графов  $M$ . Под расстоянием в  $M$  будем понимать функцию  $\rho(G,H) = p_G + p_H - 2p_{GH}$ , где  $G, H \in M$  – произвольные графы;  $p_G$ ,  $p_H$  – порядки графов  $G$  и  $H$  соответственно;  $p_{GH}$  – порядок пересечения  $G \cap H$ .

Функция  $\rho(G,H)$  является в некотором смысле обобщением метрики, введенной в [9] для  $p$ -вершинных графов:  $d(G,H) = t$ , где  $p+t$  – наименьшее число вершин в графе, содержащем порожденные подграфы, изоморфные  $G$  и  $H$ .

Покажем, что функция  $\rho(G,H)$  удовлетворяет аксиомам метрики

$$1) \rho(G,H) \geq 0, \quad \rho(G,H) = 0 \Leftrightarrow G \cong H,$$

$$2) \rho(G,H) = \rho(H,G),$$

$$3) \rho(G,H) + \rho(H,K) \geq \rho(G,K) \text{ для любых } G, H, K \in M.$$

Аксиомы I и 2 – очевидны; аксиому 3 можно переписать  $p_H + p_{GK} \geq p_{GH} + p_{HK}$ . Если  $p_H < p_{GH} + p_{HK}$ , то  $p_H \geq p_{GH} + p_{HK} - p_{GK}$ , а  $p_{GK} \leq p_{GH}$ , что и доказывает 3. Здесь  $p_{GK}$  – порядок пересечения  $G \cap H \cap K$ .

В практических задачах рассматриваются конечные семейства графов  $S = \{G_1, \dots, G_n\}$ . Любой граф  $G_j \in S$ ,  $j=1, \dots, n$ , можно представить точкой в  $(n-1)$ -мерном пространстве  $M$  и, зная расстояния между каждой парой графов из  $S$ , вычислить их координаты как координаты точек в  $M$ .

Пусть  $G_1, G_j \in S$ , тогда

$$\rho(G_1, G_j) = \rho_{1j} = \sqrt{\sum_{k=1}^{n-1} (x_k^1 - x_k^j)^2},$$

где  $x_k^i$  или  $x_k^j$  – k-я координата графа  $G_1$  или  $G_j$ . Если начало координат поместить в точку, соответствующую некоторому графу, помечаемому индексом "0", тогда координаты следующего графа, помеченного индексом "1", будут ( $x_1^1 = \rho_{01}, x_2^1 = 0, \dots, x_{n-1}^1 = 0$ ) и т.д., для i-го графа имеем систему из i уравнений относительно его координат

$$\left\{ \begin{array}{l} (x_1^1)^2 + \dots + (x_i^1)^2 = \rho_{01}^2, \\ (x_1^1 - x_1^i)^2 + (x_2^1)^2 + \dots + (x_i^1)^2 = \rho_{11}^2, \\ \dots \dots \dots \dots \dots \\ (x_1^1 - x_1^{i-1})^2 + \dots + (x_{i-1}^1 - x_{i-1}^{i-1})^2 + (x_i^1)^2 = \rho_{1-i, i}^2; \quad 1 \leq i \leq n-1, \end{array} \right.$$

и ее решение

$$x_k^i = (\rho_{01}^2 - \rho_{k1}^2 + \sum_{j=1}^k (x_j^k)^2 - 2 \sum_{j=1}^{k-1} x_j^i x_j^k) / 2x_k^k; \quad 1 \leq k \leq i.$$

Представление графов точками в метрическом пространстве позволяет вводить различные критерии близости и решать задачи таксономии [10] на графах. Например, все p-вершинные графы, содержащие заданный подграф порядка p<sub>1</sub>, можно заключить в шар диаметра 2(p-p<sub>1</sub>). Конкретные алгоритмы таксономии, приспособленные для работы в метрических пространствах и с различными критериями близости, изложены в [22].

Указанные задачи могут возникать при анализе связей типа "структурно-свойство", и данные методы могут применяться для исследования, например, биологической активности химических соединений.

5. Генерация структур. В системе предусматриваются средства генерации структур по заданной совокупности фрагментов и критерию подобия. Такая операция может понадобиться, например, если для некоторой выборки найдены фрагменты и есть необходимость дополнить эту выборку другими возможными структурами. Для этих целей использован программный модуль из [11].

6. Кратность и относительное положение признаков. Предусматриваются средства для описания кратности вхождения и относительного положения фрагментов в структурах и решения перечисленных задач с учетом этой информации. Такая возможность появляется благо-

даря достаточно хорошо развитому программному аппарату метрического анализа структур [12].

Более детально остановимся на описании методики исследования зависимости между структурными особенностями и свойствами молекулярных графов.

7. Корреляция между структурой и свойством. Для установления корреляции между структурой вещества и его свойствами используется следующий подход. Пусть класс соединений  $S_1 = \{G_1^1, \dots, G_{N_1}^1\}$ , где  $G_i^1, i = 1 \dots N_1$ , - графы с помеченными вершинами и ребрами, представляющие структурные формулы соединений, проявляющие некоторый вид активности. Это может быть вызвано присутствием некоторого фрагмента  $F$ , который входит в структуру каждого из данных соединений, что может быть выражено в виде  $F = \bigcap_{i=1}^{N_1} G_i^1$ . На практике может

оказаться, что общий фрагмент, принадлежащий пересечению одновременно всех структур из  $S_1$ , представляет собой "недостоверный" признак, так как достаточно часто встречается у соединений, не проявляющих данного вида активности. Такая ситуация может быть вызвана существованием нескольких структурных фрагментов, ответственных за наличие данного вида активности. Вследствие этого представляется более разумным рассматривать все максимальные попарные пересечения структур  $G_i^1 \cap G_j^1, 1, j \in \{1, \dots, N_1\}, i < j$ , и формировать набор потенциальных признаков, из которого затем выбирать подмножество таких структурных характеристик, по сочетанию которых можно достаточно надежно определять наличие интересующего свойства. Как уже говорилось в п.3, под пересечением графов  $G$  и  $H$  понимается максимальный по включению порожденный общий подграф  $K$ , компоненты связности которого рассматриваются в качестве множества признаков.

Для повышения надежности распознавания можно одновременно с классом  $S_1$ , рассматривать и другой класс соединений  $S_2 = \{G_1^2, \dots, G_{N_2}^2\}$ , обладающий другим видом активности и формировать набор потенциальных признаков одновременно для двух классов (можно рассматривать и большее число классов).

Такой подход к отбору совокупности признаков позволяет исключать из рассмотрения признаки, достаточно часто встречающиеся у веществ, не обладающих заданной активностью.

Признак, который часто встречается у представителей одного класса и редко (или совсем не встречается) у представителей другого класса, имеет большую вероятность войти в информативное подмножество. Отсюда следует, что нет смысла тратить усилия на поиск общих фрагментов для молекул из разных классов – если такие и найдутся, они не войдут в информативный набор. Это замечание позволяет уменьшить перебор, сосредоточив внимание на поиске общих фрагментов только в молекулах веществ из одного и того же класса.

В качестве объекта, к которому применяется методика выбора информативных признаков, используется секционированная таблица  $T = \{t_{ij}\}$  типа "объект-признак". Строки таблицы с номерами  $i = \{1, \dots, m\}$  соответствуют графам  $G_i$ , представляющим структуры, а столбцы с номерами  $j = \{1, \dots, l\}$  соответствуют признакам (или фрагментам)  $F_j$ . Секция таблицы  $S_\alpha$ ,  $\alpha = \overline{1, q}$ , – это множество ее строк, соответствующих структурам одного класса. Значения элементов таблицы  $t_{ij}$  вычисляются следующим образом:  $t_{ij} = 1$ , если  $F_j$  содержится в  $G_i$ , или  $t_{ij} = 0$ , если  $F_j$  не содержится в  $G_i$ .

В задачах распознавания сначала формируется полная таблица, а затем делается попытка построить решающее правило, определяющее связь между значениями  $t_{ij}$  признаков  $F_j$  объекта  $G_i$  и его принадлежностью к своему классу  $S_\alpha$ .

8. Поиск общих подграфов и заполнение таблицы "объект-свойство". Для нахождения общих подграфов графов  $G$  и  $H$  используется метод, являющийся развитием метода, описанного в [24], и основанный на свойствах графов соответствий  $L$ , который определяется как модульное произведение этих графов  $L = G \nabla H$ .

**ОПРЕДЕЛЕНИЕ I.** Пусть  $G(V, X), H(U, Y)$  – неориентированные, неизоморфные, без петель и кратных ребер графы;  $V, U$  – множества вершин,  $X, Y$  – множества ребер графов  $G$  и  $H$  соответственно. Графом соответствий для графов  $G$  и  $H$  (или их модульным произведением) называется граф  $L(W, E)$ , множество вершин которого  $W = V \times U$ ; т.е.  $W = \{w = \{v, u\} | v \in V, u \in U\}$ , а множество ребер определяется следующим отношением смежности вершин  $w = \{v, u\}, w' = \{v', u'\}$  графа  $L$ :

$$(w, w') \in E \Leftrightarrow \{(v, v') \in X, (u, u') \in Y\} \vee \\ \vee \{(v, v') \notin X, (u, u') \notin Y, v \neq v', u \neq u'\}.$$

Табличное представление операции модульного произведения приведено на рис. 4.




Рис.4

Граф соответствий содержит полную информацию о возможных соответствиях вершин графа  $G$  вершинам графа  $H$ , и основное его свойство состоит в том, что каждый максимальный полный подграф (клика) графа  $L$  соответствует максимальному общему подграфу графов  $G$  и  $H$ . Иначе говоря, если  $\langle w_1, \dots, w_k \rangle$  — клика графа  $L$ ,  $w_i = \{v_i, u_i\}$ ,  $v_i \in V$ ,  $u_i \in U$ ,  $i=1, k$ , то подграфы  $\langle v_1, \dots, v_k \rangle \subseteq G$  и  $\langle u_1, \dots, u_k \rangle \subseteq H$  максимальны и изоморфны.

Таким образом, для получения максимальных пересечений графов  $G$  и  $H$  достаточно построить  $L = G * H$  и найти в  $L$  клики наибольшего порядка и, применяя операцию модульного произведения к каждой паре химических структур из некоторого семейства, как к графам с помеченными вершинами и ребрами, можно получить полное множество их максимальных попарных пересечений. Но для этого требуется определить операцию модульного произведения для помеченных графов.

**ОПРЕДЕЛЕНИЕ 2.** Пусть  $G(V, X)$  и  $H(U, Y)$  — графы с помеченными вершинами и взвешенными ребрами. Введем однозначные отображения  $m: V, U \rightarrow R^+ \cup \{0\}$  и  $r: X, Y \rightarrow R^+ \cup \{0\}$ , где  $R$  — множество действительных чисел. Графом соответствий для графов  $G$  и  $H$  называется граф  $L(W, E)$ , множество вершин которого  $W \subseteq V \times U$ :

$$\begin{aligned} W &= \{w = \{v, u\} | m(v) = m(u), v \in V, u \in U\}, \\ (w, w') \in E &\Rightarrow \{r(v, v') = r(u, u')\} \& \{(v, v') \in X, (u, u') \in Y, v \neq v', \\ &u \neq u'\} \vee \{(v, v') \in X, (u, u') \in Y\}. \end{aligned}$$

Заметим, что определение 1 является частным случаем определения 2, когда все метки вершин совпадают и веса ребер одинаковы.

Величина перебора, определяемая порядком графа соответствий, который в худшем случае равен произведению порядков исходных графов, и сложность алгоритма поиска клик [13], даже в сравнительно простых случаях, велика и затрудняет практическое решение задач. Для сокращения перебора используются данные топологического анализа структур и способы упрощения графа соответствий, основанные на учете метрических свойств графов [12, 14], использованием свойств симметрий [15, 16] и рекурсивном разборе графов при поиске клик [17-19].

8.1. Анализ метрических свойств графов и свойств симметрий. Пусть  $G$  и  $H$  — помеченные графы. Вершины, имеющие одинаковые метки, будем называть сравнимыми. Зафиксируем некоторую пару сравнимых вершин  $v \in V$ ,  $u \in U$  и будем считать, что все попарно сравнимые вершины в графах  $G$  и  $H$  должны находиться на одинаковых расстояниях от  $v$  и  $u$  соответственно.

Множество сравнимых вершин в этих графах может быть построено путем определения относительных разбиений [14].

**ОПРЕДЕЛЕНИЕ 3.** Относительным разбиением графа  $G(v, x)$  для  $v \in V$  называется множество  $\hat{G}(v) = \{V_i(v), i = \overline{0, e(v)}\}$ ,  $\bigcup_{i=0}^{e(v)} V_i = V$ ,  $V_i \cap V_j = \emptyset$ ,  $i \neq j$ ;  $V_0 = \{v\}$ ,  $v' \in V_i \Leftrightarrow d(v, v') = i$ ,  $i = \overline{1, e(v)}$ , где  $e(v)$  — эксцентризитет вершины  $v$ ,  $d(v, v')$  — расстояние между  $v$  и  $v'$ . На рис. 5 приведены примеры относительных разбиений.




Рис. 5

Чтобы найти максимальные общие подграфы графов  $G$  и  $H$ , состоящие из сравнимых вершин, достаточно искать клики не во всем графе соответствий  $L$ , а только в некоторых его подграфах, определяемых как модульные произведения относительных разбиений:  $\hat{L} = \hat{G}(v) \nabla \hat{H}(u)$ .

**ОПРЕДЕЛЕНИЕ 4.** Пусть  $\hat{G}(v)$  и  $\hat{H}(u)$  — относительные разбиения графов  $G$  и  $H$ . Модульным произведением относительных разбиений называется порожденный подграф  $\hat{L}(w', x')$  графа  $L(W, E)$ , множество

вершин которого определяется как  $w' = \{v', u'\} \in W' \Leftrightarrow w' \in \bigcup_{i=0}^k V_i(v) \times U_i(u)$  и  $m(w') = m(u')$ ,  $k = \min(e(v), e(u))$ .

Применение операции модульного произведения над разбиениями позволяет заменить анализ сложного графа анализом множества более простых графов. В общем случае такое множество порождается всеми парами относительных разбиений для сравнимых вершин графов  $G$  и  $H$ .

Эффективность вычислений зависит не только от количества разбиений для сравнимых вершин, но и от их сложности, которая определяется числом и порядком слоев. Чем длиннее разбиения и чем меньше вершин в слоях, тем проще графы соответствий.

**ЗАМЕЧАНИЕ.** Клики в модульных произведениях относительных разбиений могут не порождать максимальных общих подграфов исходных графов. Это обстоятельство связано с тем, что в построении модульного произведения участвуют только вершины графов  $G$  и  $H$  из слоев с одинаковыми номерами, т.е. в модульном произведении  $\hat{G}(v) \nabla \hat{H}(u)$  не может присутствовать  $w' = \{v', u'\}$ , где  $v' \in V_i(v)$ ,  $u' \in U_j(u)$ ,  $i \neq j$ , что не позволяет охватить все возможное множество соответствий вершин графа  $G$  вершинам графа  $H$ . Так, для графов на рис. 5 вершины из слоя  $V_3$ , а в случае, когда рассматриваются произведения с  $\hat{H}(7')$ , и вершины из  $V_2$  не участвуют в построении модульных произведений разбиений и поэтому не могут попасть в общие подграфы. Тем не менее очевидно, что  $G \simeq H \setminus \{7'\}$ .

В общем случае вопросы "полноты" модульных произведений разбиений составляют предмет специального исследования. Здесь заметим, что такая ситуация может возникнуть, когда в одном из графов присутствуют вершины с большой степенью, что крайне редко встречается в химических структурах. С другой стороны, потеря максимальности общего подграфа происходит, как правило, за счет отдельных мелких компонент связности, которые в большинстве случаев все же попадают в число признаков (при анализе других пар структур), и такая потеря компенсируется значительным сокращением времени решения задачи.

Переход к модульным произведениям разбиений позволяет сократить порядок анализируемых графов соответствий, а для того, чтобы уменьшить их число, используется информация об орбитах групп автоморфизмов графов  $G(H)$  и  $H(G)$ . Поиск орбит осуществляется алгоритмом [17].

Пусть  $g \in \Gamma(G)$  и  $gv = v'$ ,  $v, v' \in V$ ,  $v = v'$ . Поскольку автоморфизмы сохраняют смежность, то под действием  $g$  разбиение  $\hat{G}(v)$  перейдет в  $\hat{G}(v')$ . Очевидно,  $\forall u \in U$  графы  $\hat{G}(v) \vee \hat{H}(u)$  и  $\hat{G}(v') \vee \hat{H}(u)$  изоморфны, и, следовательно, порождают изоморфные подграфы графа  $G$ . Аналогично можно рассуждать и для графа  $H$ . Это свойство графов позволяет исключить из рассмотрения множество лишних изоморфных структурных фрагментов, порождаемых симметриями, при этом их количество может быть найдено без перебора. Если известно разбиение множества вершин графа на непересекающиеся части, в которых для каждой пары вершин существуют автоморфизмы, переводящие их друг в друга, то говорят, что заданы орбиты графа.

Как отмечено выше, любая пара вершин из одной и той же орбиты при анализе модульных произведений соответствующих относительных разбиений будет порождать изоморфные общие подграфы, и так как нас интересует только наличие того или иного фрагмента в исследуемой молекуле (число вхождений фрагмента в молекулу может быть вычислено), то при построении модульных произведений достаточно рассматривать по одной вершине из каждой орбиты графов  $G$  и  $H$ .

Например, график  $G$  (рис.5) имеет только одну орбиту:  $(1,2,3,4,5,6)$ , а график  $H$  – две орбиты:  $(1,2,3,4,5,6)$  (7). Чтобы получить все неизоморфные общие подграфы для  $G$  и  $H$ , достаточно рассмотреть произведения  $\hat{G}(1) \vee \hat{H}(1')$  и  $\hat{G}(1) \vee \hat{H}(7')$ .

8.2. Рекурсивный разбор и кликовая база графа. Для поиска клик в графике модульного произведения используется алгоритм рекурсивного разбора графов [18,19] и его модификация – алгоритм поиска клик максимального порядка, которые определяют наибольшие общие подграфы исходных графов. Экспоненциальный рост числа клик с увеличением порядка графа ограничивает практическую применимость алгоритмов перечисления клик, однако, в ряде задач оказывается достаточным находить не все клики графа, а только кликовую базу [15], т.е. множество клик, непереводящихся друг в друга автоморфизмами графа.

Используемый алгоритм [16] нахождения максимальных клик из базы графа основан на рекурсивном разборе и использует в качестве входной информации орбиты группы автоморфизмов.

Рассмотрим график модульного произведения. Вершины  $w = \{v, u\}$  и  $w' = \{v', u'\}$  будем считать принадлежащими одной орбите, если выполнено условие  $(\exists g \in \Gamma(G) | g = v') \wedge (\exists h \in \Gamma(H) | hv = u')$ . Заметим, что такое определение орбит не охватывает всех симметрий мо-

дульного произведения, но оказывается достаточным для практических целей.

Пусть  $K = \langle w_1, \dots, w_n \rangle$  и  $K' = \langle w'_1, \dots, w'_n \rangle$  – автоморфные клики, т.е.  $w_i$  и  $w'_i$  принадлежат одной и той же орбите модульного произведения,  $i = \overline{1, n}$ . Тогда очевидно, что  $K$  и  $K'$  порождают изоморфные подграфы в исходных графах  $G$  и  $H$ . Таким образом, при поиске максимальных пересечений графов можно ограничиваться нахождением максимальных клик из кликовой базы модульного произведения.

При поиске максимальных пересечений можно пользоваться следующей оценкой [24] порядка клик в  $\hat{G}(v) \cap \hat{H}(u)$ . Пусть  $m_j(v_i), \dots, m_{k_1}(v_i)$  – количества вершин с метками  $M_1, \dots, M_{k_1}$  в слое  $V_i$  разбиения  $\hat{G}(v)$ ,  $i = \overline{1, e(v)}$ , а  $m_j(u_i), \dots, m_{k_2}(u_i)$  – количества вершин с метками  $M_1, \dots, M_{k_2}$  в слое  $U_i$  разбиения  $\hat{H}(u)$ ,  $i = \overline{1, e(u)}$ .

Если в слое нет вершин с некоторой меткой  $M_j$ , то  $m_j(v_i) = 0$  или  $m_j(u_i) = 0$ . Порядок максимальной клики в  $\hat{G}(v) \cap \hat{H}(u)$  не может превышать величины

$$Q(v, u) = \sum_{i=1}^k \sum_{j=1}^l \min(m_j(v_i), m_j(u_i)),$$

где  $k = \min(e(v), e(u))$ ,  $l = \max(k_1, k_2)$ .

Если порядок уже найденной клики в  $\hat{G}(v) \cap \hat{H}(u)$  превышает величину  $Q(v', u')$ , то нет необходимости рассматривать  $\hat{G}(v') \cap \hat{H}(u')$ , так как максимальной клики здесь заведомо не содержится.

Итак, при нахождении наибольших общих подграфов в графах  $G$  и  $H$  выполняются следующие процедуры.

1. Находятся симметрии (орбиты групп автоморфизмов) графов  $G$  и  $H$  и производится выбор "вершин-представителей".

2. Строятся относительные разбиения для "вершин-представителей" и вычисляются оценки.

3. Строится модульное произведение разбиений и находятся его симметрии.

4. Происходит поиск максимальных базовых клик в модульном произведении и сравнение их порядка с оценками нерассмотренных разбиений.

5. Исключаются тождественные пересечения графов  $G$  и  $H$ . (Если одна клика  $K$  порождает подграф  $F_1 \simeq \langle v_1, \dots, v_n \rangle \subseteq G$  и  $F_2 \simeq \langle u_1, \dots, u_n \rangle \subseteq H$ , а клика  $K'$  порождает подграф  $F_2 \simeq \langle v'_1, \dots,$

$\dots, v_n' \rangle \subseteq G$  и  $F_2 \cong \langle u_1, \dots, u_n \rangle \subseteq H$ , то  $F_1 \cong F_2$  и  $F_2$  исключается. Аналогично исключается  $F_2 \cong \langle v_1, \dots, v_n \rangle \cong \langle u_1', \dots, u_n' \rangle$ .

8.3. Исключение изоморфных признаков - подграфов и формирование таблицы "объект - признак". Выше были изложены принципы и методы поиска наибольших общих подграфов двух графов. Теперь переходим к нахождению общих подграфов для семейств графов, формированию множества признаков и заполнению таблицы "объект-свойство".

$S_\alpha$	$G_1^\alpha$	...	$G_i^\alpha$	...	$G_j^\alpha$	...	$G_{N_\alpha}^\alpha$
$G_1^\alpha$	■						
			■				
				■			
					■		
						...	
							■

$G_{i,j}^\alpha \equiv G_i^\alpha \cap G_j^\alpha$

Рис.6

де таблицы (рис.6). Каждое пересечение  $G_i^\alpha \cap G_j^\alpha$  определяется подстановкой вида

$$\tau_{i,j}^\alpha = \begin{pmatrix} i_1 & \dots & i_n \\ j_1 & \dots & j_n \end{pmatrix},$$


где  $\langle i_1, \dots, i_n \rangle$ ,  $\langle j_1, \dots, j_n \rangle$  - порожденные подграфы  $G_i^\alpha$  и  $G_j^\alpha$  соответственно.

Для каждого фиксированного  $i$ ,  $1 \leq i \leq N_\alpha - 1$ , подстановка  $\tau_{i,k}^\alpha$ ,  $i+1 < k \leq N_\alpha$ , сравнивается со всеми подстановками  $\tau_{i,k'}^\alpha$ ,  $i < k' < k$ , по наборам номеров вершин в графе  $G_i^\alpha$  (рис.7, а), при совпадении очевидно, что подграф, определяемый подстановкой  $\tau_{i,k}^\alpha$ , изоморден подграфу, порожденному  $\tau_{i,k'}^\alpha$ , и подграф  $G_i^\alpha \cap G_{k'}^\alpha$  исключается из набора признаков.

Для  $1 \leq i \leq N_\alpha - 1$  каждая  $\tau_{i,i}^\alpha$ ,  $i < i \leq N_\alpha$ , дополнительно сравнивается с  $\tau_{i,i}^\alpha$  по наборам номеров вершин графа  $G_i^\alpha$  и с  $\tau_{j,i}^\alpha$ ,  $j < i$ , по наборам номеров вершин графа  $G_j^\alpha$  (рис.7, б).

Пусть получены все попарные пересечения графов из класса химических структур  $S_\alpha = \{G_1^\alpha, \dots, G_{N_\alpha}^\alpha\}$ . Если

некоторый подграф  $G_i^\alpha \cap G_j^\alpha$  состоит из нескольких компонент, то каждая компонента рассматривается в качестве отдельного подграфа-признака. Множество пересечений  $G_i^\alpha \cap G_j^\alpha$ ,  $1 \leq i \leq j \leq N_\alpha$ , удобно изображать в ви-






a)

б)

Рис. 7

ПРИМЕР. Исключение изоморфных пересечений для семейства химических структур  $S = \{G_1, G_2, G_3\}$ :



$$\tau_{12} = \begin{pmatrix} 2 & 3 & 4 & 5 & 6 & 7 & 8 & 9 & 10 & 11 & 12 \end{pmatrix},$$

$$\tau_{13} = \begin{pmatrix} 8 & 9 & 10 & 11 & 12 \end{pmatrix}, \quad \tau_{23} = \begin{pmatrix} 9 & 10 & 11 & 12 & 13 \end{pmatrix}.$$

Набор пересечений состоит из трех фрагментов, определяемых подстановками:  $F_1 \equiv \tau_{12}$ ,  $F_2 \equiv \tau_{13}$ ,  $F_3 \equiv \tau_{23}$ . Фрагменты  $F_2$  и  $F_3$ , изоморфны, так как совпадают наборы элементов в подстановках для графа  $G_3$ , поэтому  $F_3$  исключается.

После того, как исключены изоморфные признаки-подграфы внутри каждого рассматриваемого класса  $S_\alpha$ ,  $\alpha = \overline{1, q}$ , производится непосредственная проверка изоморфизма между признаками в различных классах. Если некоторый признак  $F_1$  изоморден признаку  $F_2$ , то при исключении  $F_2$  запоминаются структуры, в которые признак  $F_2$  входит как подграф, и считается, что в эти структуры входит признак  $F_1$ .

Когда сформирован набор неизоморфных признаков  $\{F_1, \dots, F_k\}$  решается задача вложения признака  $F_j$ ,  $j = \overline{1, l}$ , в каждую из исходных структур, в которых не было зафиксировано присутствие признака  $F_j$  (задача вложения сводится к поиску максимального общего подграфа, порядок которого должен совпадать с порядком графа  $F_j$ ) и заполняется таблица "объект-признак"  $T = \|t_{ij}\|$ ,  $i = \overline{1, n}$ ,  $j = \overline{1, l}$ , где

$$n = \sum_{\alpha=1}^q N_\alpha; t_{ij} = \begin{cases} 1, & \text{если } F_j \text{ входит в } i\text{-ю структуру,} \\ 0, & \text{если } F_j \text{ не входит в } i\text{-ю структуру.} \end{cases}$$

9. Нахождение систем признаков структурного различия [20]. Если таблица  $T$  содержит 1 столбцов, то в общем случае для выбора разделяющей совокупности признаков, по значениям которых можно было бы с определенной надежностью распознать, к какому классу принадлежит та или иная молекула, необходимо осуществить перебор, равный  $C_n^l$ . Для реальных ситуаций эта величина достаточно велика.

Существуют эвристические алгоритмы [21], которые достаточно быстро позволяют найти разделяющие системы признаков. При помощи этих алгоритмов из двоичных\*) признаков  $x_j$  формируются "вторичные" признаки  $y_i = x_{i_1}^{\sigma_1} x_{i_2}^{\sigma_2} \dots x_{i_k}^{\sigma_k}$ ,  $\sigma_j \in \{0, 1\}$ ,  $x^0 = \bar{x}$ ,  $x^1 = x$ . Каждый признак  $y_i$  должен быть "истинным" на возможно большем числе объектов одного класса и ложным на всех объектах других классов. Набор признаков  $T = \cup_i y_i$  должен полностью "покрыть" соответствующий класс таблицы  $T$ . Это значит, что условие  $T = 1$  будет

\*) Для случая бинарных таблиц.

выполняться для всех структур данного класса, а для всех структур других классов  $\Upsilon = 0$ .

Набор  $\Upsilon$  есть булева функция от переменных (признаков)  $x$ , представленная в дизъюнктивной нормальной форме над множеством конъюнкций  $u_1$ . Эта функция на множестве из первого класса равна единице, а на множестве другого класса – равна нулю. Поскольку задачи анализа структур обладают спецификой, по сравнению с другими аналогичными задачами, то была предпринята попытка проанализировать существующие программы, предназначенные для построения решающих правил [22], с целью оценки возможности их приложения для решения указанных задач.

10. Экспериментальные данные о работе комплекса SISTRAN и исследовании программ построения решающих правил.

10.1. Программная реализация комплекса SISTRAN осуществлена в рамках ОС ЕС на языке ПЛ/И и использует мультизадачный режим для совмещения операций ввода-вывода с процессорными вычислениями. В комплекс включены следующие программы, имеющие свое функциональное назначение:

1. Транслирующая программа ОГРА-30.

2. Программы, обеспечивающие загрузку и накопление структур и найденных фрагментов.

3. Анализ симметрий структур.

4. Нахождение и формирование связных неизоморфных подграфов-признаков: поиск всех попарных пересечений исходных структур в семействе, нахождение компонент связности в пересечениях, определение симметрий пересечений, исключение изоморфных фрагментов и их накопление в виде таблицы, проверка изоморфного вхождения фрагментов в исходные структуры.

Комплекс позволяет обрабатывать семейства графов, состоящие из неограниченного числа классов. Каждый класс может состоять из не более 400 структур порядка  $\leq 50$ . Эти ограничения не принципиальны, они являются следствием выбранного варианта форматов данных и могут быть легко изменены. Для опробования возможностей комплекса программ SISTRAN было выбрано семейство из 160 барбитуратов [1]. Из данного семейства в качестве обучающей выборки были рассмотрены два класса соединений с определенными ограничениями времени угнетающего воздействия.

К первому классу были отнесены 18 соединений (табл.1)  $t > 300$  мин, а ко второму классу 14 соединений (табл.2)  $t < 15$  мин.

Т а б л и ц а I.  
Класс барбитуратов,  $t > 300$  мин.

№	R	R'	T
54	$\text{CH}_3\text{CH}_2-$	$\text{CH}_2=\text{O}(\text{CH}_3)\text{CH}_2-$	326
55	"-	$\text{CH}_3\text{CH}=\text{CHCH}_2-$	372
56	"-	$\text{CH}_3\text{CH}_2\text{OCH}(\text{CH}_3)-$	460
53	"-	$\text{CH}_2=\text{CHCH}(\text{CH}_3)-$	720
14	"-	$\text{CH}_3\text{CH}_2-$	1400
13	"-	$\text{CH}_3\text{CH}_2\text{CH}_2-$	1140
16	"-	$\text{CH}_3\text{CH}(\text{CH}_3)-$	1520
17	"-	$\text{CH}_3\text{CH}_2\text{CH}_2\text{CH}_2-$	450
18	"-	$\text{CH}_3\text{CH}(\text{CH}_3)\text{CH}_2-$	540
19	"-	$\text{CH}_3\text{CH}_2\text{CH}(\text{CH}_3)-$	600
1	$\text{CH}_3-$	$(\text{CH}_3)_3\text{CCH}_2-$	580
12	"-	$\text{CH}_3\text{CH}_2\text{SCH}_2-$	330
88	$\text{CH}_3\text{CH}_2\text{CH}_2-$	$\text{CH}_2=\text{CHCH}(\text{CH}_3)-$	420
127	$\text{CH}_2=\text{OCH}_2-$	$\text{CH}_2=\text{CHCH}(\text{CH}_3)-$	456
131	"-	$(\text{CH}_3)_3\text{CCNOCH}_2$	900
132	"-	$\text{CH}_2=\text{C}(\text{CH}_3)\text{CH}_2-$	380
139	"-	$\text{CH}_2=\text{CHCH}_2-$	880
140	"-	$(\text{CH}_3)\text{CH}_2-$	720

щих правил. Программа ТККБ для Т(I,2) построила следующие решающие правила: если  $\chi_i(G) = 1 \Rightarrow G$  принадлежит  $i$ -му классу,  $i = \{1,2\}$ , то

$$\chi_1 = x_{32}x_{23} \vee \bar{x}_{32}\bar{x}_{49}\bar{x}_{46}\bar{x}_{47} \vee \bar{x}_{32}\bar{x}_{49}\bar{x}_{46}x_{47}x_{11}, \quad (1)$$

$$\chi_2 = \bar{x}_{32}x_{49} \vee x_{32}\bar{x}_{23} \vee \bar{x}_{32}\bar{x}_{49}x_{46} \vee \bar{x}_{32}\bar{x}_{49}\bar{x}_{46}x_{47}\bar{x}_{11}. \quad (2)$$

В этих правилах каждая конъюнкция истинна только на объектах своего класса, т.е. по этим правилам все структуры данной обучен-

Из этих классов была сформирована 2-х секционная таблица Т(I,2) (табл.3), в которой число признаков-фрагментов равно 6I.

Приведем данные, характеризующие параметры комплекса SISTRAN.

Пепарные пересечения для первого класса строились 153 раза, для второго класса - 9I раз. С учетом связности набор признаков состоял из 660 (325 - первый и 335 - второй классы) фрагментов. После исключения изоморфных подграфов набор содержал 6I признак. Время работы - 25 мин (ЕС-1050).

Для обработки полученной таблицы Т (табл.3) с целью получения решающих правил применялись программы TREE [23], DW [22].

#### 10.2. Построение решающих правил

Таблица 2

Класс барбитуратов,  $t < 15$  мин

№	R	R'	T
48	$\text{CH}_3\text{CH}_2-$	$(\text{CH}_3)_2\text{CHCH}=\text{CH}-$	12
51	-"-	$\text{CH}_3(\text{CH}_2)_3\text{CH}=\text{C}(\text{CH}_3)-$	6
52	-"-	$\text{CH}_3\text{CH}_2\text{CH}=\text{C}(\text{CH}_3\text{CH}_2\text{OH}_2)-$	6
69	-"-	$\text{CH}_3(\text{CH}_2)_5\text{SCH}_2-$	15
71	-"-	$\text{CH}_3\text{CH}_2\text{SCH}(\text{CH}_3\text{CHCH}_3)-$	12
77	$\text{CH}_3\text{CH}_2\text{CH}_2-$	$\text{CH}_3\text{CH}_2\text{CH}_2\text{CH}_2\text{CH}_2-$	4
79	-"-	$\text{CH}_3(\text{CH}_2)_5-$	1
80	-"-	$\text{CH}_3(\text{CH}_2)_6-$	15
100	$(\text{CH}_3)_2\text{CH}-$	$(\text{CH}_3)_2\text{CHCH}=\text{CH}-$	12
107	$\text{CH}_3(\text{CH}_2)_3-$	$\text{CH}_3\text{CH}_2\text{CH}(\text{CH}_3)-$	16
108	-"-	$(\text{CH}_3)_3\text{C}-$	1
109	-"-	$\text{CH}_3\text{CH}=\text{CH}-$	12
155	$\text{CH}_3\text{CH}_2\text{SCH}_2-$	$(\text{CH}_3)_3\text{CCH}_2-$	8
157	$\text{CH}_3\text{CH}_2\text{SCH}(\text{CH}_3)-$	$\text{CH}_3(\text{CH}_2)_5-$	12

щей выборки распознаются без ошибок. Программа не делает оценки качества решающих правил, что делает затруднительным выбор необходимых решающих правил. Время работы - 37 сек (БЭСМ-6, FORTRAN).

Программа DW для T(1,2) построила правила:

$$Y_1 = \bar{x}_6 \vee \bar{x}_6 \bar{x}_{3_2} x_5 \vee \bar{x}_6 x_{3_2} x_{3_2} \vee \bar{x}_6 \bar{x}_{3_2} \bar{x}_5 \bar{x}_{14} \bar{x}_{47} \vee \bar{x}_6 \bar{x}_{3_2} \bar{x}_5 \bar{x}_{14} x_{47} x_{14}, \quad (3)$$

$$Y_2 = \bar{x}_6 x_{3_2} \bar{x}_{2_3} \vee \bar{x}_6 \bar{x}_{3_2} \bar{x}_5 x_{14} \vee \bar{x}_6 \bar{x}_{3_2} \bar{x}_5 \bar{x}_{14} x_{47} \bar{x}_{11}. \quad (4)$$

Все структуры распознаются без ошибок. Оценка качества решающего правила путем скользящего экзамена составила 18,75%. Время - 17 сек (EC-I050, FORTRAN). В табл.4 приведены признаки-фрагменты, используемые в решающих правилах.

С целью оценки качества решающих правил, полученных по T(1,2), из семейства барбитуратов была сформирована контрольная выборка, в

Таблица 3

Таблица "структурно-признак" для двух классов

№ структуры	
54	111111111110 10000000000000000000 10000000000000000000 11000000000000000000 00000000000000000000 00000000000000000000
12	111000100 11100000000000000000 10000000000000000000 11000000000000000000 10000000000000000000 10000000000000000000
55	11101011110 11110000000000000000 10000000000000000000 11000000000000000000 00000000000000000000 00000000000000000000
132	101100110 110111110 0000000000 10000000000000000000 11000000000000000000 00000000000000000000 00000000000000000000
88	111001100 10 10 10 100 1111000000 10000000000000000000 11000000000000000000 1100 10 100 10
17	11101010000 10000000 1000 10000000 10 110,10000 11111000000000000000 00000000000000000000 00000000000000000000
127	101001100 10 10 111100 1100 10000000 10 00000000 11000000000000000000 1100 10 10000 00000000000000
56	111000110 10 1000000000 1000 1100 1000000000 11000000000000000000 11000000000000000000 1100 10 10000 000000000000
18	11101011110 10000000000000000000 10000000000000000000 11000000000000000000 10000000000000000000 00000000000000000000
1	101000100 11100000000000000000 11100000000000000000 11000000000000000000 00000000000000000000 00000000000000000000
19	111000110 10 10 10000000 1000 1000 1000000000 11000000000000000000 1100 10 10000 00000000000000
53	1110001110 10 10 10 1000 1100 1000 1000000000 11000000000000000000 1100 10 10000 00000000000000
140	1010001100 10 10 1111000 100 10000000 11000000000000000000 11000000000000000000 1100 10 10000 000000000000
139	00100110110 11111100000000000000 10000000000000000000 11000000000000000000 00000000000000000000 00000000000000000000
131	10100110110 11111100000000000000 11110000000000000000 11000000000000000000 00000000000000000000 00000000000000000000
15	11101011110 1000000000 100 1100000 1000 00000000 11000000000000000000 11000000000000000000 00000000000000000000
14	11101011110 10000000000000000000 10000000000000000000 11000000000000000000 00000000000000000000 00000000000000000000
16	111000110 10 1000000000 1000 1000 1000000000 11000000000000000000 11000000000000000000 1100 10 10000 000000000000
79	11100010 110 10000000 100 10000000 10 111111110 11100000000000000000 11000000000000000000 00000000000000000000
106	111000100 10 10000000 1000000000 110 10 10000000 11111000000000000000 11000000000000000000 00000000000000000000
77	11100010 110 10000000 100 10000000 10 11110 100 1110 11100000000000000000 11000000000000000000 00000000000000000000
51	111000110 10 10 10000000000000000000 100 10 10000000 1110 100 10000000000000000000 11000000000000000000 00000000000000000000
52	111000110 10 10 10000000000000000000 10000000 10000000 11000000000000000000 11000000000000000000 00000000000000000000
155	11100010 110 10 10000000000000000000 10 10000000 11000000000000000000 11000000000000000000 1100 0000 1000 10000 0000
48	111000110 10 10 10000000000000000000 1000000000 11000000000000000000 11000000000000000000 11100000 1000 10000 0000
71	111000110 10 10 10000000000000000000 1000000000 11000000000000000000 1000 1111100 1000 1111100 1000
100	1000000000 10 10 10000000000000000000 1000000000 11000000000000000000 1000 11000 1000 11000 10000000000000
109	111000100 10 10 1000000000 10 1000000000 10 10 10000000 11111000000000000000 10000000 10000000
157	111000100 10 10000000 10 1000000000 10 10 11110 1110 1110 1000 111110 11110 11110 1000 111110 111111
69	11101011110 10000000000000000000 10000000000000000000 10 11100 1110 10 100 100000 1000 100000 100000
80	11100010 110 10000000 100 10000000 10 111110 11110 11100000000000000000 10000000000000000000 10000000000000000000
107	111000100 10 10 10000000 10 1000000000 10 10 10000000 11111000000000000000 1100 10 1000 11

которую вошли соединения со временем угнетающего воздействия  $t = 300$  мин (№ 23, 28, 89, I28, I29, I50) и со временем  $I5 < t < 30$  мин (№ II, 43, 47, 70, 82, 83, 86, 87, 99, I01, I02, II0, I24, 74, 96, I58).

Результаты распознавания приведены в табл. 5 (I - объект классифицирован правильно, 0 - неправильно). Из таблицы видно, что соединения со временем воздействия  $t = 300$  мин по решающим правилам (3)-(4), (I)-(2) относятся к первому классу. Вещества со временем воздействия  $I5 < t < 30$  распознаются хуже, так, по правилам (3)-(4) неправильно распознаны 4 объекта, а по правилам (I)-(2) - 12 объектов. Таким образом, для данных выборок решающие правила, построенные программой DW, обеспечивают более надежное

Таблица 4 распознавание контрольной выборки, чем правила, построенные программой TREE.

№	Признак-фрагмент
6	$\text{CH}_2-$
14	$-\text{CH}=$
32	$\text{CH}_3(\text{CH}_2)_3-$
47	$\text{CH}_3-\text{CH}_2-\text{S}-$
5	$-\text{CH}_2-\text{B}-\text{CH}_2-\text{CH}_3$
11	$\text{CH}_3-\text{B}-\text{CH}_2-$
23	$-(\text{CH}_2)_2-\text{B}-\text{CH}_2-\text{CH}_3$
46	$\text{CH}_3-\text{CH}_2-\text{B}-\text{C}=\text{CH}-\text{CH}_2$
49	$-\text{B}-\text{CH}=\text{CH}-\text{CH}(\text{CH}_2)-$

ЗАМЕЧАНИЕ. Результаты применения правил (3)-(4) становятся лучше, если рассматривать  $15 < t < 20$  мин (неправильно распознается только один объект). Это позволяет предположить, что "граница" первого класса лежит в области значения  $t = 20$ .

Для рассмотренных программ безразлично какое значение принимают признаки, нуль или единица, - главное, чтобы их значения максимально различали объекты из разных классов. Отсюда в решающих правилах может воз-

никать большое количество отрицаний наличия признаков у объектов.

В некоторых задачах предсказания свойств химических соединений большее значение имеет факт наличия некоторого фрагмента, а не его отсутствия. В связи с этим возникает необходимость в построении и анализе таких алгоритмов, которые бы позволили учитывать приоритет признаков и пытались бы сначала строить решающее правило по ненулевым значениям признаков и только в случае неудачи - по нулевым.

Легко проверить, что часть таблицы Т, построенная для первого класса и признаков 5, 6, 11, 14, 23, 32, 46, 47, 49, не содержит единиц в строчках для структур 8, 11, 18. Откуда следует, что эти структуры по наличию признаков не классифицируются. Следует также отметить, что желательна реализация методики предварительного отбора признаков, т.е. дополнительные алгоритмические условия построения таблицы Т, при которых она строилась бы постепенно и одновременно с попытками получения решающих правил. Такой подход может сократить время вычислений, так как для реальных семейств структур решающие правила могут быть найдены раньше, чем построены все попарные пересечения, что требует наиболее трудоемких вычислений.

Приведем один способ построения таких систем признаков. Пусть часть признаков построена. После формирования каждого нового признака будем проверять его на необходимость, а систему признаков с его участием - на достаточность. Необходимым считается признак, у которого не все элементы одинаковы, и если он не пол-

Таблица 5

N	T	DW	THREE
23	300	1	1
28	300	1	1
89	300	1	1
128	300	1	1
129	300	1	1
150	300	1	1
11	24	1	1
43	18	1	0
47	24	1	0
70	22	0	0
82	18	1	0
83	18	1	1
86	18	1	0
87	24	1	0
99	18	1	0
101	18	1	0
102	18	1	0
110	18	1	1
124	18	0	0
74	28	1	1
96	25	0	0
158	28	0	0

ностью совпадает с любым другим ранее найденным признаком. Если признак оказался необходимым, его добавляют в таблицу и полученную таким путем систему признаков проверяют на достаточность.

Достаточной для распознавания класса является такая система признаков, по которой удается построить решающую функцию, отличающую молекулу этого класса от молекулы всех других классов в достаточно большом числе случаев.

Если на очередном шаге система признаков оказалась недостаточной, то порождается очередной признак, проверяется на необходимость, а новая система проверяется на достаточность. Процедура продолжается до тех пор, пока все или заданный процент молекул данного класса не будет распознаваться правильно.

Затем аналогичный процесс построения решающего правила делается для молекул следующего класса. При этом вначале проверяется, не достаточно ли имеющаяся система признаков для построения надежного правила распознавания молекул класса, и если нет – порождается очередной признак.

Процесс заканчивается тогда, когда будет построен набор правил, по которым с заданной точностью будут распознаваться молекулы всех классов, представленных в таблице "объект-признак".

### Заключение

Рассмотрена методика нахождения наибольших общих подграфов для всех пар графов из данного семейства, основанная на применении относительных разбиений. Рассмотрены вопросы применения данной методики для исследования связи "структурно-активность" для структур молекулярных графов, а также указаны необходимые функции пакета программ, предназначенного для анализа и распознавания химических структур.

Исследована применимость методов распознавания образов для задачи прогнозирования свойств, основанной на общих фрагментах.

Обращается внимание на необходимость разработки методов построения решающих правил для бинарных таблиц, которые бы, по возможности, не использовали отрицаний признаков.

### Л и т е р а т у р а

1. СТЫОПЕР Э., БРЮГТЕР У., ДЖУРС П. Машинный анализ связи химической структуры и биологической активности. -М.: Мир, 1982. - 235 с.
2. Методы представления и обработки структурной информации для анализа связи структура-активность /Гитлина Л.С., Голендер В.Е., Дробоглав В.Б. и др.-Рига, 1981. - 74 с. (Препринт/ Ин-т органического синтеза АН ЛатвССР).
3. ЯРОВОЙ С.С. Методы расчета физико-химических свойств углеводородов. -М.: Химия, 1978. - 256 с.
4. Исследование эффективности некоторых статистических алгоритмов предсказания биологической активности многоатомных молекул /Ингматуллин Р.С., Осипов А.Д. и др. - В кн.: Использование вычислительных машин в спектроскопии молекул и химических исследованиях. VI Всесоюз. конф. Тез. докл. Новосибирск, 1983, с.22-23.
5. КОЧЕТОВА А.А., СКОРОБОГАТОВ В.А., ХВОРОСТОВ П.В. Язык описания структурной информации ОГРА-30. -В кн.: Машинные методы обнаружения закономерностей, анализа структур и проектирования (Вычислительные системы, вып. 92), Новосибирск, 1982, с. 70-79.
6. ВЛЭДУЦ Г.Э., ГЕЙВАНДОВ Э.А. Автоматизированные информационные системы для химии. -М.: Наука, 1974. - 48 с.
7. CORNELL D.G., GOTTLIEB C.G. An efficient algorithm for graph isomorphism. - Journal ACM, 1970, v.17, p.51-64.
8. ДЕНИЩИК Е.Ю., СКОРОБОГАТОВ В.А., ХВОРОСТОВ П.В. Нахождение общих подструктур в семействах химических соединений.-В кн.: Использование вычислительных машин в спектроскопии молекул и химических исследованиях: VI Всесоюз. конф. Тезисы докл. Новосибирск, 1983, с. 197-198.
9. ZELINKA B. On a certain distance between isomorphism classes of graphs.- Cas.pest.mat., 1975, v.100, N 4, p.371-373.
10. ЗАГОРУЙКО Н.Г. Методы распознавания и их применение. -М.: Сов. радио, 1972. - 206 с.
11. МОЛОДЦОВ С.Г., ПИОТРУХ-ПЕЛЕЦКИЙ В.Н. Построение всех неизоморфных химических графов из заданного набора структурных фрагментов. -Настоящий сборник, с. 51-58.
12. СКОРОБОГАТОВ В.А., ХВОРОСТОВ П.В. Анализ метрических свойств графов. -В кн.: Методы обнаружения закономерностей с помощью ЭВМ (Вычислительные системы, вып. 91). Новосибирск, 1981, с. 3-20.
13. БЕССОНОВ Ю.Е., СКОРОБОГАТОВ В.А. Применение относительных разбиений при поиске клик. -В кн.: Автоматизация проектирования в микроэлектронике. Теория. Методы. Алгоритмы (Вычислительные системы, вып. 77). Новосибирск, 1978, с. 25-33.
14. СКОРОБОГАТОВ В.А. Относительные разбиения и слои графов. -В кн.: Вопросы обработки информации при проектировании систем (Вычислительные системы, вып. 69). Новосибирск, 1977, с. 3-10.

15. СКОРОБОГАТОВ В.А., ХВОРОСТОВ П.В. Орбиты, клики, канонизация. -В кн.: Методы и программы решения оптимизационных задач на графах и сетях: Тезисы докл. Всесоюз. совещ. Новосибирск, 1980, с. 85-87.
16. СКОРОБОГАТОВ В.А., ХВОРОСТОВ П.В. Анализ симметрий графов. -В кн.: Методы и программы решения оптимизационных задач на графах и сетях: Тезисы докл. II Всесоюз.совещ. Ч.2. Новосибирск, 1982, с. 43-45.
17. БЕССОНОВ Ю.Е., СКОРОБОГАТОВ В.А., ХВОРОСТОВ П.В. Алгоритм нахождения кликовой базы графа. -Там же, с. 16-18.
18. БЕССОНОВ Ю.Е., СКОРОБОГАТОВ В.А. Об одном семействе схем рекурсивного разбора графов. -В кн.: Машинные методы обнаружения закономерностей, анализа структур и проектирования (Вычислительные системы, вып. 92). Новосибирск, 1982, с. 3-49.
19. БЕССОНОВ Ю.Е., СКОРОБОГАТОВ В.А. О рекурсивном разборе графов. -В кн.: Алгоритмические основы обработки структурной информации (Вычислительные системы, вып. 85). Новосибирск, 1981, с.3-20.
20. ЗАГОРУЙКО Н.Г., СКОРОБОГАТОВ В.А. Выбор признаков структурного различия классов химических веществ. -Там же, с. 92-93.
21. ЛБОВ Г.С., КОТЮКОВ В.И., МАШАРОВ Ю.П. Метод поиска логических закономерностей на эмпирических таблицах. -В кн.: Эмпирическое предсказание и распознавание образов (Вычислительные системы, вып. 67). Новосибирск, 1976, с. 29-41.
22. ЗАГОРУЙКО Н.Г., ЛБОВ Г.С., МАШАРОВ Ю.П. Пакет прикладных программ для обработки таблиц экспериментальных данных ОТЭКС-1. -В кн.: Вопросы обработки информации при проектировании систем (Вычислительные системы, вып. 69). Новосибирск, 1977, с. 93-101.
23. ЛБОВ Г.С., ФРОЛОВА Т.И. Комплект программ для анализа данных с использованием логических решающих функций. -В кн.: Тезисы докл. II Всесоюз. школы-семинара "Программно-алгоритмическое обеспечение прикладного многомерного статистического анализа". М., 1983, с. 103-104.
24. СКОРОБОГАТОВ В.А. Нахождение общих частей в семействах графов. -В кн.: Материалы Всесоюзного совещания "Прикладные задачи на графах и сетях". Новосибирск, 1981, с. 117-132.

Поступила в ред.-изд.отд.  
10 мая 1984 года