

Информационный мониторинг в задаче прогнозирования риска развития сердечно-сосудистых заболеваний

Н.М. Ахмеджанов, А.В. Жукоцкий, Р.Г. Оганов,
В.Б. Кудрявцев, А.П. Рыжов, В.В. Расторгуев,
А.С. Строгалов.

1. О задаче информационного мониторинга

Термин «информационный мониторинг» было предложено использовать в 1991 – 1992 годах в научной печати [3] для общего обозначения формализованных моделей действий специализированных человеко-машинных интеллектуальных информационных систем, предназначенных для формирования оценок состояния актуальных проблем на базе фрагментарной, ненадежной, возможно недостоверной информации о них и моделирования возможных вариантов развития проблем в зависимости от изменения текущих оценок и параметров модели. В отличие от широко применяемых систем традиционного мониторинга (например, экологического, медицинского, технического и т.п.), базирующихся на анализе большого количества результатов показаний различных измерительных приборов, датчиков, накопленной статистики и др., приставка «информационный» подчеркивает, что для интересующих нас систем «входом» являются не только показания приборов исключительно в числовой форме, а и некоторая нечисловая информация (хотя могут использоваться и показания измерительных устройств). Иначе говоря, мы создаем информационные системы, использующие не только результаты измерений технических устройств, но и качественные оценки человеком различной информации, представленной в виде текстов,

событий, действий по достижению, например, каких-то целей и т.д. — тем самым мы включаем человека, как регулярно действующий «измерительный прибор», в систему мониторинга. Такое расширенное толкование систем мониторинга оказалось достаточно удачным — оно позволило не только использовать методологию разработки систем мониторинга в сфере информационных технологий, но и сформулировать достаточно широкий и интересный с точки зрения приложений класс информационно-аналитических задач, решаемых на основе этого подхода. В свою очередь для создания действующих систем информационного мониторинга и отработки технологии их создания в различных предметных областях пришлось разработать ряд теоретических проблем и задач в таких научных направлениях как теория измерений, теория нечетких множеств, многозначные логики; потребовалось привлечение подходов и методов, развиваемых в теории генетических алгоритмов и теории нейронных сетей. В основном, эти проблемы связаны с математико-компьютерным моделированием свойств человека как «измерительного устройства» для оценки ситуаций на основе недостоверной, противоречивой, семантически сложно-структурированной информации. Следовательно, системы информационного мониторинга представляют собой человеко-компьютерные системы, ориентированные на обработку разнородной, разноуровневой, фрагментарной, нечеткой и ненадежной информации по некоторой проблеме (или набору проблем). Эти системы ориентированы на эксперта-аналитика и позволяют ему на основе всей доступной информации:

- единообразно обрабатывать разнородную, разноуровневую, фрагментарную, ненадежную, меняющуюся во времени информацию;
- получать интегральную оценку состояния проблемы в целом, ее аспектов и признаков на текущий момент времени;
- проводить ретроспективный анализ состояния проблемы в целом, ее аспектов и признаков;
- моделировать различные ситуации в предметной области и на основе этого выбирать стратегии, позволяющие максимально улучшить состояние проблемы в будущем;

- выявлять «критические пути» развития проблемы, то есть те элементы проблемы, малое изменение состояния которых может качественно изменить состояние проблемы в целом.

Учитывая особенности информации (разнородность, разноуровневость, фрагментарность, нечеткость и ненадежность) и конкретных способов ее обработки, основные черты технологии информационного мониторинга можно изложить следующим образом:

- для возможности обработки фрагментарной информации используется модель проблемы в виде иерархической структуры (древовидного графа [8]). Ясно, что для сложных проблем такое представление модели возможно является несколько упрощенным, однако при этом достигается хорошая наглядность и простота работы с моделью проблемы без потери ее существенных свойств;
- обработка информации различной степени надежности и обладающей возможной недостоверностью, противоречивостью или, может быть, тенденциозностью достигается за счет использования лингвистических оценок экспертами данной информации.

Для того, чтобы отделить технологию информационного мониторинга от других технологий обработки символической информации, мы опишем более подробно ее суть и сравним ее с другими технологиями (имитационное моделирование, экспертные системы (ЭС) и др.)

2. Обоснование выбора технологии исследований

Содержание работы многих классов специалистов в современном информационном обществе можно представить как работу по определенным проблемам. В общем виде она заключается в оценке текущего состояния проблемы на основе всей доступной информации, построении прогнозов ее развития и выработке рекомендаций по управлению развитием проблемы, исходя из целей, стоящих перед специалистом. Примерами таких проблем могут быть:

- в области медицины — «Возможность возникновения массовых эпидемий в связи с развитием неблагоприятных факторов», «фетоинфантильные потери [12] и проблема «зловещие клещи» (Г. Комаров) — небывалое превышение общей смертности над рождаемостью в 90-х годах прошлого века в России» и т.д. Информация в данных случаях представляет собой результаты исследований медиков, социологов, опросов общественного мнения, высказывания политиков и госчиновников (финансовая сфера), оценки конкретных действий министерств, управлений, госкомитетов страны и т.п.
- в области фармацевтической индустрии — «Возможность производства фирмой *X* лекарства (препарата, суспензии и т.д.), аналогичного *Y*», «Целесообразность производства лекарства (препарата, суспензии и т.д.) *Z*», «Экологическая безопасность производства медико-биологических препаратов» и т.д. Информация представляет собой результаты маркетинговых исследований, оценки экспертов, анализ колебаний цен на мировых рынках, законодательства стран, модели технологических процессов и т.п.
- в области науки — «Нечеткие и интеллектуальные технологии в кардиологии (рентгенодиагностике, УЗИ и т.д.)», «Мембранные технологии», «Экология и альтернативные источники энергии». Информация фиксируется в научных статьях, выступлениях на конференциях, оценках специалистов, обзорах, отчетах и т.п.

Данный список можно продолжать и продолжать.

Будем называть задачу оценки текущего состояния проблемы и построения прогнозов ее развития задачей информационного мониторинга, а человеко-компьютерные системы, обеспечивающие информационную поддержку подобного рода информационным задач, системами информационного мониторинга.

Основными элементами системы мониторинга на верхнем уровне являются информационное пространство, в котором циркулирует информация о состоянии проблемы, и эксперт (эксперты), работающие с этой информацией и делающие выводы о состоянии проблемы и прогнозах ее развития.

Информационное пространство представляет собой совокупность различных информационных элементов, которые можно охарактеризовать следующим образом:

- *разнородность носителей* информации, то есть фиксация информации в виде статей, газетных заметок, компьютерном виде, аудио и видеоинформация и т.п.;
- *фрагментарность*. Информация чаще всего относится к какому-либо фрагменту проблемы, причем разные фрагменты могут быть по-разному «покрыты» информацией;
- *разноуровневость*. Информация может относиться ко всей проблеме в целом, к некоторой ее части, к конкретному элементу проблемы;
- *различная степень надежности*. Информация может содержать конкретные данные различной степени надежности, косвенные данные, результаты выводов на основе надежной информации или косвенные выводы;
- *возможная противоречивость*. Информация из различных источников может совпадать, слегка различаться или вообще быть противоречивой;
- *изменяемость во времени*. Проблема развивается во времени, поэтому и информация в разные моменты времени об одном и том же элементе проблемы может и должна различаться;
- *возможная тенденциозность*. Информация отражает определенные интересы источника информации, поэтому может носить тенденциозный характер. В частном случае она может являться намеренной дезинформацией (например, для политических проблем или для проблем, связанных с конкуренцией).

Эксперты являются активным элементом системы мониторинга и, наблюдая и изучая элементы информационного пространства, делают выводы о состоянии проблемы и перспективах ее развития с учетом перечисленных выше свойств информационного пространства. Обычно эксперты образуют некоторую структуру (отдел маркетинга фирмы, консультационную службу, агентство, министерство и

т.п.). В этом случае каждый эксперт «нижнего уровня» имеет дело с некоторой частью проблемы и работает с элементами информационного пространства, эксперты «более высокого уровня» имеют дело с более крупными фрагментами проблемы или проблемой в целом и работают уже с выводами предыдущих экспертов. При этом они могут ознакомиться с выводами более низкого уровня вплоть до элементов информационного пространства.

Для разработки компьютерных систем, ориентированных на решение задачи мониторинга и обработку такого рода информации, были проанализированы известные технологии обработки информации (технология баз данных, технология баз знаний или экспертных систем, гипертекстовые технологии обработки информации и т.п.). Ни одна из них не удовлетворяет полностью функциональным требованиям к системе. Сравнительные характеристики различных информационных технологий приведены в таблице 1. Поэтому возникла необходимость разработки некоторой специальной технологии, поддерживающей создание такого рода систем.

Сравнительный анализ наиболее близкой технологии экспертных систем и технологии информационного мониторинга, а также характеристик их предметных областей приведен в таблицах 2 и 3.

Системы информационного мониторинга базируются на теории иерархических нечетких дискретных динамических систем и позволяют:

- единообразно обрабатывать разнородную, разноуровневую, фрагментарную, ненадежную, меняющуюся во времени информацию;
- получать оценки состояния проблемы, отдельных ее аспектов;
- моделировать различные ситуации в предметной области мониторинга;
- выявлять «критические пути» развития проблемы, то есть выявлять те элементы проблемы, малое изменение состояния которых может качественно изменить состояние проблемы в целом.

Технологию информационного мониторинга можно назвать технологией информационной поддержки *конкретного пользователя*,

Технология	Основная идея	Причина отторжения
Исследование операций	Можно построить математическую модель объекта управления. Модель можно оптимизировать относительно некоторых параметров (ограничений).	«Непонятность» модели для пользователя. Неразвитость прикладной части.
Имитационное моделирование	Можно построить приближенную модель объекта, имитирующую его реальное поведение.	«Непонятность» модели для пользователя. Трудность работы при введении новых параметров.
Диалоговые системы	Можно построить естественно-языковой интерфейс к математическим и/или имитационным моделям.	«Непонятность» моделей для пользователя. Трудности реализации интерфейса.
Экспертные системы	Можно извлечь у экспертов знания о решении задач и использовать их при решении практических проблем.	«Закрытость» вывода. Невозможность обработки фрагментарной и ненадежной информации.
Системы поддержки принятия решений	Гибридность, то есть совместное использование всех перечисленных выше технологий.	Следуют из основной идеи.

Таблица 1. Эволюция средств поддержки принятия решений

которая, по нашему мнению, является естественным продолжением развития средств информационной поддержки (см. таблицу 1).

Свойство	ТЭС	ТИМ
Наличие базы знаний	***	***
Наличие базы данных	**	***
Возможность совместной обработки данных и знаний	*	***
Наличие машины вывода	***	
Наличие подсистемы объяснения (убеждения)	***	
Глубокий логический вывод	***	*
Возможность декомпозиции системы	*	***
Возможность обработки фрагментарной информации	*	***
Возможность обработки динамических данных	*	***
Возможность обработки ошибочных данных		***
Полилогичность	*	***
Возможность обработки нечеткой информации	*	***

Таблица 2. Сравнительный анализ технологии экспертных систем (ТЭС) и технологии информационного мониторинга (ТИМ).




Таблица 3. Содержательный анализ характеристик предметных областей экспертных систем и систем информационного мониторинга.

Учитывая особенности информации и конкретных способов ее обработки, основные черты технологии информационного мониторинга можно изложить следующим образом.

Эта технология базируется на использовании ряда элементов, позволяющих обрабатывать подобного рода информацию. В частности:

- для реализации возможности обработки информации из различных источников, в базе данных системы хранятся как сами документы, так и ссылки на них с оценкой содержащейся в них информации, данной экспертом;

- для возможности обработки фрагментарной информации используется модель Проблемы в виде дерева. Ясно, что для сложных проблем такое представление модели является несколько упрощенным, однако при этом достигается хорошая наглядность и простота работы с моделью проблемы;
- обработка разноуровневой информации достигается за счет предоставления пользователю возможности отнести оценку конкретного информационного материала к разным вершинам дерева-модели. Учитывая представление модели проблемы в виде дерева, число признаков более низкого уровня всегда делается избыточным для определения признака верхнего уровня;
- обработка информации различной степени надежности и обладающей возможной противоречивостью или тенденциозностью достигается за счет использования лингвистических оценок экспертами данной информации;
- изменяемость во времени учитывается фиксацией даты поступления информации при оценке конкретного материала, то есть время является одним из элементов описания объектов системы.

Таким образом, системы, построенные на базе этой технологии, позволяют иметь развивающуюся во времени модель проблемы на основе оценок экспертов, подкрепленную ссылками на все информационные материалы, выбранные экспертами, с общими и частными оценками состояния Проблемы или ее аспектов, описанными на основе нечеткой логики. Использование времени как параметра системы позволяет проводить ретроспективный анализ и строить прогнозы развития Проблемы (отвечать на вопросы типа «Что будет, если...?»). В последнем случае возникает возможность выделения «критических путей», то есть таких элементов модели, малое изменение которых может вызвать значительные изменения в состоянии всей Проблемы. Знание таких элементов имеет большое практическое значение и позволяет выявить «слабые места» в Проблеме на текущий момент времени, разработать мероприятия по блокированию нежелательных ситуаций (например, рост числа заболеваний, распространение эпидемий

и т.д.) или провоцированию желательных (профилактика, вакцинация, устранение факторов риска), то есть в некоторой степени управлять развитием Проблемы в интересах организации, ее отслеживающей (например, Государственный научно-исследовательский центр профилактической медицины МЗ РФ — ГНИЦПМ МЗ РФ).

Разрабатываемая новая информационная технология может иметь большой спектр приложений в таких областях как, например, экология, безопасность вредных производств и др., кроме того позволит решить на систематической основе ряд теоретических, технических и технологических проблем, что сделает имеющуюся информационную технологию более гибкой и универсальной.

3. Информационный мониторинг в медико-биологических исследованиях

Достаточно широкий класс задач медико-биологического характера может быть сформулирован в терминах технологии информационного мониторинга, на основе которой возможно создание действующих человеко-компьютерных комплексов по наиболее актуальным проблемам здравоохранения. Причем возможно решение проблем как на медико-социальном уровне, так и на уровне отдельных индивидуумов заданной когорты (группы, определяемой по заданным показателям). Иначе говоря, такие задачи сводятся к отслеживанию развития некоторой проблемы (возможно набора проблем), ее отдельных аспектов и признаков, прогнозированию и выявлению «критических» путей ее развития на основе единой технологии. К такому классу относятся, к примеру, задачи диагностики, задачи объективизации оценки лечебных воздействий, прогноза. Крайне актуальным представляется внедрение методов информационного мониторинга для анализа репродуктивно-демографических процессов в нашей стране [12], имеющих в последние годы негативную тенденцию в ряде регионов. Заметим, что в отличие от задач автоматической диагностики мы не ставим диагноз на основе экспертных знаний, «защитых» в компьютерную программу, а даем оценку тенденциям в изменении, например, состояния популяции в зависимости от изменения сово-

купности факторов, влияющих на состояние, и это влияние можно самому оценить (открытые экспертные знания) и изменить по своему мнению (в случае несогласия с экспертной оценкой). Более подробно об этом будет сказано ниже. Для отработки технологии информационного мониторинга в области медицины была для начала взята одна из задач, лежащих в области научной тематики ГНИЦПМ МЗ РФ по отслеживанию состояния здоровья населения России.

Известно, что особенное внимание в России и в мире уделяется заболеваниям, обусловленным атеросклерозом [13], при которых холестерин, накапливаясь в стенках артерий сужает их просвет, что ухудшает кровоснабжение различных органов (сердца, мозга, почек, нижних конечностей — так называемых «органов-мишеней»). Таким образом ограничивается поток крови в артериях, нарушается гемодинамика, что, в свою очередь, может вызывать, в частности, повышение артериального давления, тромбообразование и др. Проблема атеросклеротических заболеваний остро стоит и в западных странах, где на здравоохранение выделяются существенные средства, прикладываются огромные усилия государственных и частных структур, фармацевтические компании вкладывают в создание эффективных лекарств миллиарды долларов. И, по-видимому, не зря: так, по данным American Heart Association, в США от сердечно-сосудистых заболеваний каждые 33 секунды умирает один человек. Россия — страна с одним из самых высоких показателей смертности от сердечно-сосудистых заболеваний [13, 18]. При этом финансирования, которое получают ведущие медицинские центры страны, занимающиеся проблемой атеросклероза и его последствий, явно недостаточно для борьбы с этим заболеванием. Поэтому перед институтом профилактической медицины МЗ РФ встала естественная задача разработки методик и отслеживания на новом технологическом уровне факторов риска атеросклеротических заболеваний у населения России, прогнозирования дальнейшей динамики заболеваний этого класса в различных его возрастных группах и выработки наиболее экономически эффективных способов уменьшения риска.

Эта задача хорошо вписывается в класс задач, решаемых на основе технологий информационного мониторинга: есть специалисты высокого уровня, обладающие достаточными экспертными знаниями по

проблемам атеросклеротических заболеваний, накоплена обширная база знаний по этой тематике, достаточная для построения содержательной модели предметной области и др. Наличие такого рода факторов и позволило подойти к решению проблемы отслеживания факторов риска атеросклеротических заболеваний именно при помощи технологии информационного мониторинга.

4. Методы оценки риска

В кардиологии разработано много разных методов оценки риска атеросклеротических заболеваний на основе учета различных факторов, которые дают, вообще говоря, различные результаты. Однако наличие расхождений в результатах не дает повода ставить вопрос о том, какой из методов «правильнее». Проиллюстрируем сказанное следующим примером: допустим специалисту известно, что риск заболевания в какой-нибудь группе населения равен, например, 18%. Значит ли это, что из 100 человек атеросклерозом заболеет 18? Разумеется, нет. Эти цифры имеют смысл только в качестве *уровня, порядка* риска. Для этого же специалиста риск 18% и риск 20% — это практически одно и то же, поскольку это числа одного *порядка*. Поэтому добиваться максимальной точности при оценке риска — задача, как видим, зачастую не всегда нужная и, как правило, дорогая и неэффективная. Дорогая же она потому, что для получения точных формул, выражающих зависимость риска от различных факторов, необходимо при помощи статистических методов обработать огромные массивы данных, полученных в процессе проведения множества исследований, верифицировать результаты исследований и т.д. При этом требуется большая организационная и совместная научно-исследовательская работа специалистов в области статистических методов, информатиков, медиков, биологов и т.д.

Такого рода рассуждения привели нас к мысли о создании собственной подсистемы оценки рисков, которая оказалась необходимой по следующим причинам:

- **Понятность.** Благодаря собственной системе оценки рисков, специалисты получают понятную и прозрачную систему, они

знают, как она работает — в отличие от формул, которые, по сути, представляют собой «черный ящик», то есть не отражают *смысла* зависимостей риска от его факторов.

- Более простая **адаптация** к нашей задаче. В собственную систему оценки рисков можно включать ту и только ту информацию, а также те и только те факторы, которые представляют интерес для специалистов. Это такие факторы, которые удовлетворяют двум противоречивым и раскрываемым далее критериям отбора — адекватности и доступности. В существующих же формулах набор факторов жестко задан и изменить его нельзя.
- **Гибкость**. В собственную систему оценки рисков можно очень просто добавлять новые факторы или удалять ненужные. Кроме того, также просто можно изменять зависимости между факторами, то есть адаптировать модель так, как это необходимо специалистам. В существующих же формулах добавление в нее (или удаление из нее) каких-либо факторов может привести к необходимости повторного проведения статистического анализа всего объема данных.

5. Построение системы информационного мониторинга

Чтобы эффективно использовать технологию информационного мониторинга, то есть для создания системы информационного мониторинга, необходимо предварительно выполнить следующие задачи:

- 1) Построить структурную модель предметной области.
- 2) Построить поведенческую модель предметной области (модель правил).
- 3) Собрать необходимую информацию.
- 4) Заполнить модель информацией.

Рассмотрим эти этапы в процессе их выполнения.

Этап 1: Построение структурной модели

На первом этапе требуется построить структурную модель уровня риска сердечных заболеваний. Для этого, в результате серии встреч со специалистами ГНИЦПМ МЗ РФ, были выделены и описаны основные факторы риска, определены шкалы их значений, заданы их характеристики.

В настоящее время насчитывают более 30 факторов, действие которых влияет на риск возникновения и развития атеросклероза и его осложнений. Поэтому при построении структурной модели необходимо руководствоваться двумя взаимоисключающими (противоречивыми) критериями:

- 1) Адекватность. Это означает, что в модель должны быть включены все факторы, имеющие важность для описания предметной области.
- 2) Доступность информации. Как было указано выше, на третьем шаге подготовки технологии к использованию, необходимо заполнить построенную модель реальной информацией. Поэтому в модель нужно включать только те факторы, по которым можно легко и достаточно дешево получить требуемую информацию. То есть избыток факторов в модели повлечет существенное увеличение стоимости использования технологии.

После консультаций со специалистами Института профилактической медицины были выделены следующие ключевые факторы риска.

- 1) Уровень холестерина в крови.
Холестерин транспортируется в крови внутри липопротеидов. Существуют липопротеиды высокой плотности (ЛВП — так называемый «хороший» холестерин) и низкой плотности (ЛНП — «плохой» холестерин). Считается, что именно ЛНП оказывает наибольшее влияние на риск заболевания атеросклерозом.
 - а) Липопротеиды высокой плотности (ЛВП).
Считается, что ЛВП переносят холестерин из стенок артерий в печень для переработки и удаления из организма.

б) Липопротеиды низкой плотности (ЛНП).

Считается, что именно они являются переносчиком холестерина в стенки артерий.

- 2) Уровень триглицеридов (ТГ).
Триглицериды сами по себе не играют решающей роли в развитии сердечных заболеваний. Однако они имеют большое значение в совокупности с другими факторами риска. На практике высокие уровни триглицеридов очень часто сочетаются с низкими уровнями холестерина высокой плотности, то есть «хорошим холестерином», и это указывает на то, что частички жира поступают в кровь, что является причиной болезни сосудов. Поэтому высокий уровень триглицеридов должен восприниматься как сигнал опасности.
- 3) Артериальное давление.
Возникновение и темпы развития атеросклероза тесно связаны с повышенным уровнем артериального давления крови (гипертоническая болезнь). Артериальное давление характеризуется систолическим («верхнее») и диастолическим («нижнее») давлением.
- 4) Курение.
Курение значительно повышает риск развития атеросклероза и его осложнений.
- 5) Диабет.
Диабет также резко повышает риск сердечно-сосудистых заболеваний (инфаркт миокарда, инсульт, сосудистые заболевания ног и т.д.).
- 6) Физическая активность.
Низкая физическая активность значительно повышает риск сердечно-сосудистых заболеваний. Интересный пример описывает А.Л. Мясников, известнейший советский кардиолог. Он пишет: «Мы наблюдали 50-летнего рыбака, работавшего на побережье Охотского моря; он питался в значительной мере икрой, которую поглощал до 2 кг в день на протяжении 10 лет. Как известно, икра очень богата холестерином, и мы высчитали, что рыбак потреблял его в день в 10 раз больше, чем сред-

ний москвич. Несмотря на это, у него была найдена нормальная, сравнительно низкая холестеринемия; никаких признаков местных отложений холестерина (например, в передней камере глаз) и симптомов атеросклероза у рыбака найдено не было. Очевидно, работа этого человека, связанная с большим физическим напряжением, тем более в условиях полярного климата, способствовала отличной ассимиляции липидов в организме, и они не задерживались в крови и не откладывались в артериальной стенке. Следовательно, реакции, регулирующие обмен, в данном случае были адекватными в смысле усвоения пищевых веществ». Физическая активность — один из примеров информации, адекватное количественное описание которой довольно затруднительно. Конечно, можно, например, сказать, что физическая активность составляет 30 минут нагрузок в день, но такое определение не учитывает различие нагрузок.

7) Наследственность.

«Плохая» наследственность повышает риск сердечно-сосудистых заболеваний и их осложнений.

8) Питание.

Питание оказывает существенное влияние на риск развития атеросклероза: правильное питание может снизить такой риск, тогда как неправильное, особенно при неблагоприятной комбинации других ключевых факторов, может значительно его увеличить. Фактически, питание вызывает изменение уровня холестерина и триглицеридов в крови, а также артериального давления, то есть влияет на риск опосредованно, через другие факторы. Этот фактор представляет собой еще один пример ситуации, когда лингвистическое описание является значительно более удобным. Правильность питания — это агрегированный показатель, учитывающий различные виды питания:

9) Body mass index (BMI).

$$BMI = \frac{\text{вес}}{(\text{рост})^2},$$

где вес измеряется в килограммах, а рост — в метрах. Чем выше этот индекс, тем выше риск.

Многие из описанных ключевых факторов риска взаимосвязаны между собой. Например, физическая активность существенно влияет на уровень холестерина в крови, на артериальное давление, а также на вес и, следовательно, на индекс массы тела. Подобные взаимосвязи, естественно, должны быть учтены и в модели. Таким образом выстраивается иерархическая древовидная модель предметной области. Древовидная структура была выбрана, исходя из нескольких соображений:

- технология информационного мониторинга ориентирована на работу именно с такими структурами;
- относительная простота обработки деревьев;
- адекватность полученной модели.

Полученная таким образом модель изображена на рисунке 1.




Рис. 1. Построенная модель в системе информационного мониторинга.

Совершенно очевидно, что получившаяся структурная модель неполная: так, например, она не учитывает соотношение общего депо холестерина крови (10–15%) и тканей (85–90%) [13, 14]. Кроме того, при ранжировании факторов риска не определен удельный вес вклада метаболизма в синтез холестерина (до 80–85%) и его экзогенного поступления (15–20%). Тем не менее, для предварительного исследования возможностей информационного мониторинга она вполне приемлема и, кроме того, позволяет достаточно быстро и дешево получить всю информацию по используемым факторам риска.

Этап 2: Построение модели правил

По завершении этапа построения структурной модели предметной области, необходимо перейти к построению поведенческой модели, то есть задать зависимости между различными факторами риска. Эти зависимости в нашем случае были сформулированы в виде лингвистических правил. Как уже обсуждалось ранее, строгие формулы для описания зависимостей между факторами риска не очень эффективны, поскольку точные цифры не представляют особенной ценности, а служат только лишь как показатель уровня, порядка риска, при этом получение строгих зависимостей — процедура трудоемкая и требует привлечения дополнительных специалистов по статистическим методам. Поэтому для описания зависимостей между факторами риска было решено воспользоваться именно лингвистическими правилами. Одним из их несомненных достоинств является также и то, что такие правила сможет сформулировать специалист в области атеросклеротических заболеваний, то есть отпадает необходимость в привлечении специалистов в области статистических методов. Кроме того, при помощи лингвистических правил можно достаточно адекватно описать зависимости между выбранными факторами риска. В качестве оператора агрегирования информации был выбран оператор «центр масс», описанный в приложении 1 к настоящей статье.

Этап 3: Сбор информации

После того, как была построена модель нашей предметной области (структурная и поведенческая), можно приступить к сбору необходимой информации. Для этого следует провести крупномасштабное

анкетирование населения России. В ходе анкетирования у респондентов будут взяты соответствующие анализы на уровень холестерина в крови, измерено артериальное давление, выяснено качество их питания, вредные привычки (курение, алкоголь) и т.д., то есть будут оценены все факторы риска, включенные в нашу модель.

Этап 4: Заполнение модели информацией

Наконец, когда вся информация собрана, ее необходимо ввести в модель. Это осуществляется следующим образом: сначала выделяется определенная группа населения, объединенная по некоторому признаку (например, по полу или возрасту), которая в данный момент интересует специалистов. Затем данные анкетирования о значениях факторов риска по выбранной группе усредняются и вносятся в качестве факторов риска в построенную модель.

6. Создание инструментария ТИМ

Итак, после того, как подготовительный этап завершен, можно начинать практическое использование технологии информационного мониторинга. Разумеется, без специального программного инструментария все модели останутся только на бумаге, а все вычисления придется проводить вручную. Поэтому для более эффективного использования технологии и был разработан программный инструментарий, который позволял решать следующие задачи.

- Построение и обработка структурной модели предметной области. При помощи этого инструментария была построена единая иерархическая древовидная структура факторов риска атеросклеротических заболеваний. Можно достаточно легко добавлять в модель произвольные факторы, можно изменять, удалять их. Кроме того, можно работать как со всей моделью в целом, так и с отдельными ее аспектами (например, только с артериальным давлением) (см. рис. 2–4).
- Построение поведенческой модели предметной области. При помощи созданного инструментария можно достаточно легко работать с лингвистическими правилами, описывающими взаимо-

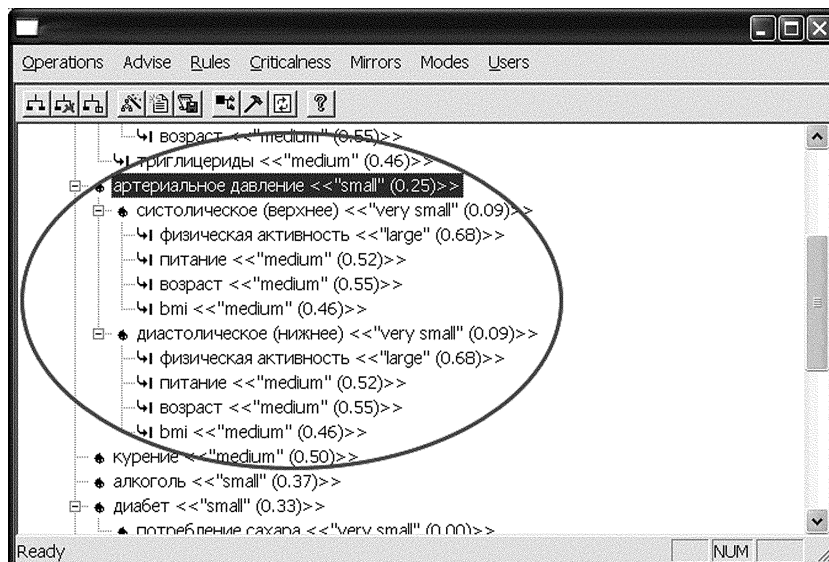


Рис. 2. Можно работать с отдельными аспектами проблемы.

связи между факторами риска — добавлять, удалять, изменять их (рис. 5).

- Получение информации о текущем состоянии проблемы в целом или отдельных ее аспектов. Можно в любой момент времени выяснить уровень риска атеросклеротических заболеваний у интересующей специалистов группы населения, а также значение различных факторов.
- Прогнозирование дальнейшего развития проблемы. Специалист, задавшись вопросом «а что будет, если *этот фактор (эти факторы)* изменится (изменятся) некоторым образом?», может достаточно легко получить на него ответ (рис. 6).
- Выявление «критических» факторов, то есть таких факторов, малое изменение которых может существенно изменить уровень риска в целом. Такая информация очень полезна для принятия решения о том, на какие факторы риска нужно воздействовать в первую очередь, чтобы максимально снизить риск заболевания населения (рис. 7).

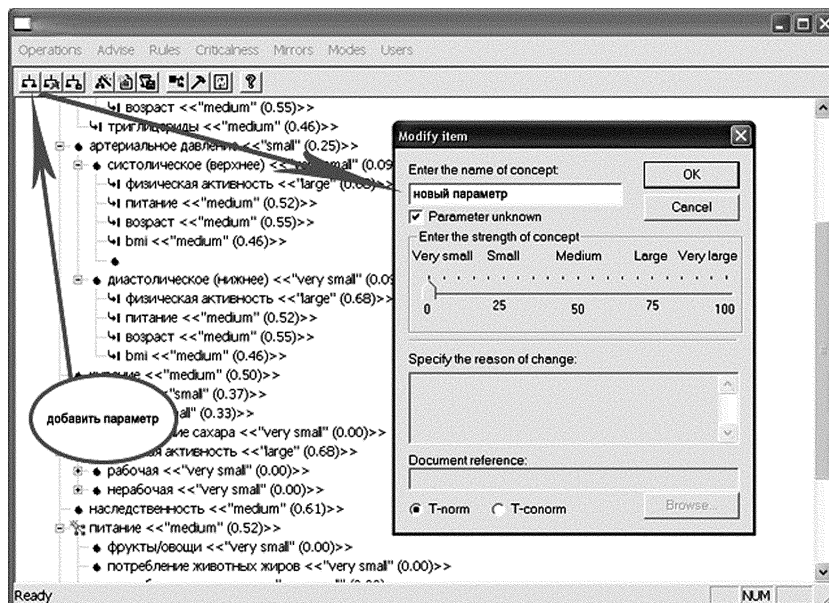


Рис. 3. Добавление новых параметров модели.

- Отслеживание истории изменений, причем как самой модели, так и информации, содержащейся в ней. Это позволяет, во-первых, выявлять динамику изменения риска в целом и отдельных его факторов; а во-вторых, в случае необходимости, осуществлять «откат» (возврат) модели в одно из ее прошлых состояний.

7. Дальнейшие направления развития

Как показал опыт построения систем информационного мониторинга, самым трудоемким этапом является построение поведенческой модели, то есть модели правил. Трудности здесь объясняются тем, что специалистам иногда, в силу различных причин, не удается сформулировать свои знания не только в виде четких формул, но и в виде лингвистических правил, либо удается лишь частично. Такими причинами могут быть и недостаточная компетентность, и так называемые

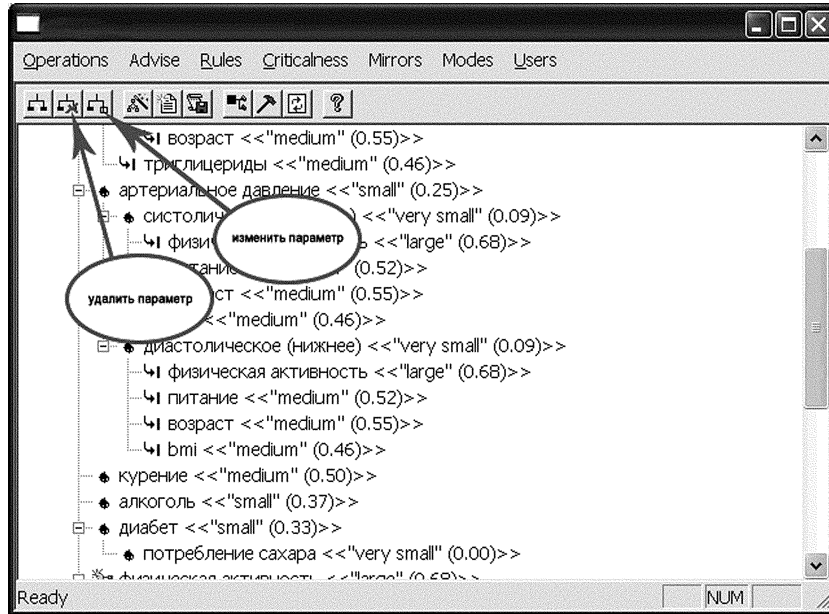


Рис. 4. Добавление и изменение параметров модели.

мые «интуитивные» знания, которые порой весьма трудно выразить вербально их носителям. Для решения этой проблемы обычно привлекаются так называемые *когнитологи* или специалисты по знаниям: они пытаются каким-то образом структурировать неструктурированные знания экспертов по предметной области и построить хотя бы приближенную ее модель. Большим недостатком такого подхода является то, что задача структурирования знаний экспертов — это скорее искусство, чем технология и, как следствие этого, привлечение подобных специалистов существенно удорожает процесс построения системы информационного мониторинга. Кроме того, когнитологи ничем не смогут помочь в случае недостаточной компетентности экспертов.

Выходом из такой ситуации может являться технология «добычи знаний» (knowledge mining или data mining). Эта сравнительно молодая технология появилась в 90-х годах XX века и применяется для ав-

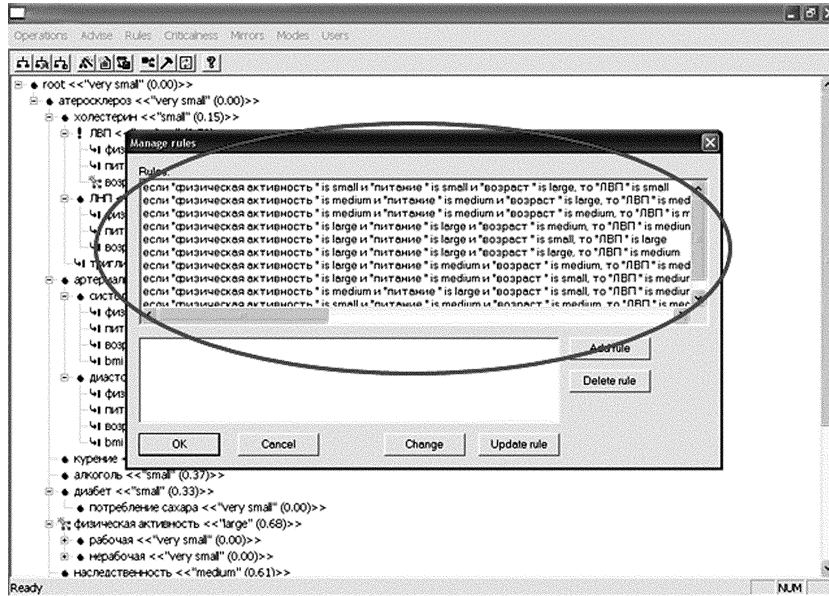


Рис. 5. Работа с лингвистическими правилами.

томатического «извлечения» структурированных знаний, например, в виде лингвистических правил, из больших объемов данных, хранящихся в соответствующих базах данных. Эта же технология может использоваться для построения поведенческой модели нашей предметной области не только на основе знаний экспертов (которые они могут сформулировать), но и на основе тех данных, которые были получены в ходе многочисленных научных исследований, посвященных проблеме атеросклеротических заболеваний.

Важным отличием «добычи знаний» от статистических методов, которые также помогают находить закономерности в больших объемах данных, является то, что на выходе «добычи знаний» получают понятные экспертам лингвистические правила, которые могут быть в дальнейшем ими уточнены и дополнены для улучшения адекватности модели. Таким образом, эта технология поможет заполнить тот пробел, который образовался вследствие того, что в силу различных причин экспертам не всегда удается сформулировать свои знания.

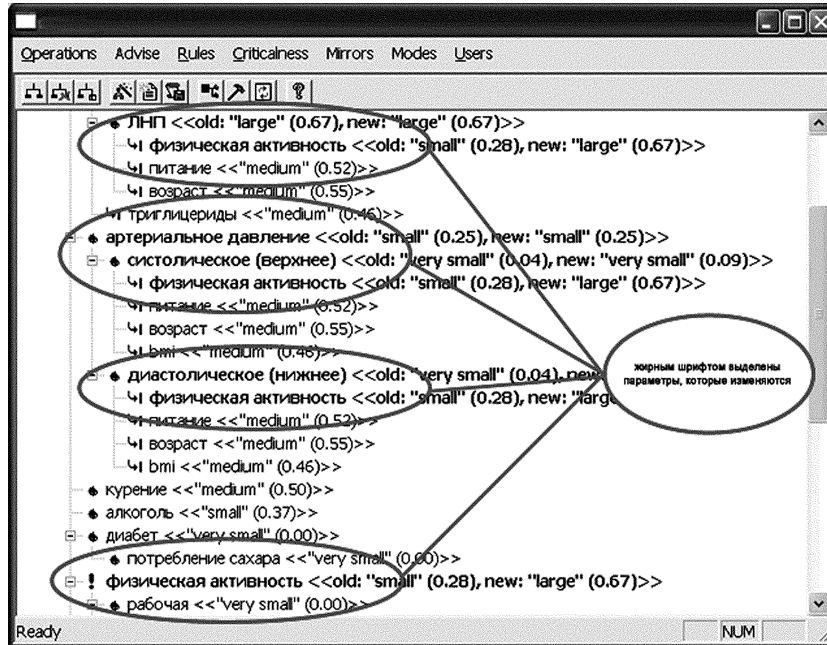


Рис. 6. Параметры, которые меняются, автоматически отображаются жирным шрифтом.

Кроме того, представляется особо перспективным совместное исследование, выполняемое в Московском научном центре по культуре и информационным технологиям (МНЦ КИТ) и в Российской медицинской академии постдипломного образования по адаптации технологии Data Mining к цифровой обработке изображений биологических объектов с применением новой информационной технологии — морфо-функциональной диагностики [15, 17] и метода компьютерной морфоденситометрии [16]. Сочетание технологии информационного мониторинга [6, 10] и методов морфо-функциональной диагностики [16] открывает новые возможности для внедрения биоинформатики и геномики в клиничко-лабораторную инструментальную диагностику, объективизацию и повышение информативности медико-социальных исследований.

The screenshot shows a software window with a menu bar (Operations, Advise, Rules, Criticalness, Mirrors, Modes, Users) and a toolbar. The main area displays a tree view of factors with their old and new criticality values. A dialog box titled 'Dialog' is open, showing a table of critical factors.

Name	Average criti...	Max criti...
ЛВП <<old: "medium" (0.50), new: "medium" (0.50)>>	37.500000	0.500000
ЛНП <<old: "large" (0.67), new: "large" (0.67)>>	25.500000	0.500000
возраст <<"medium" (0.55)>>	25.000000	0.500000
возраст <<"medium" (0.55)>>	25.000000	0.500000
холестерин <<old: "large" (0.66), new: "large" (0.66)>>	25.000000	0.500000
возраст <<"medium" (0.55)>>	25.000000	0.500000
возраст <<"medium" (0.55)>>	25.000000	0.500000
физическая активность <<old: "small" (0.28), new: "larg...	24.500000	0.500000
физическая активность <<old: "small" (0.28), new: "larg...	24.500000	0.500000
физическая активность <<old: "small" (0.28), new: "larg...	24.500000	0.500000
физическая активность <<old: "small" (0.28), new: "larg...	24.500000	0.500000
потребление сахара <<"very small" (0.00)>>	0.038230	0.000757
диабет <<"very small" (0.00)>>	0.038230	0.000757
питание <<"medium" (0.52)>>	0.000000	0.000000
питание <<"medium" (0.52)>>	0.000000	0.000000

Рис. 7. Список критических факторов с их степенью критичности.

Приложение 1

Теоретические основы

Нечеткие множества

Теория множеств и соответствующая ей булева логика составляют базу классической математики и всего, что сделано на ее основе вплоть до современных компьютерных процессоров. Модели сложных технических, физических систем, химических процессов хорошо описывались на этом языке и удачно реализовывались на компьютерах.

Ситуация поменялась коренным образом, когда возникла необходимость учитывать особенности восприятия, оценки и анализа информации человеком в качестве полноправной части моделируемой системы. Рассмотрим пример с точки зрения человека. Очевиден

некоторый парадокс: рост 179 см и 181 см для модели являются различными величинами, а 149 см и 181 см — одинаковыми (по отношению к понятию «Средний рост человека», формализованному с помощью характеристической функции множества, см. рис. 8).




Рис. 8. Характеристическая функция понятия «Средний рост человека».

Таким образом, компьютерная модель может «видеть» фактически близкие ситуации как разные, а более физически различные — как одинаковые. Этим можно было пренебрегать, пока речь шла об «игрушечных» моделях, однако при использовании математических методов в моделировании важных процессов это несоответствие становится нетерпимым. В этом несоответствии языка теории множеств и способа мышления человека и кроется одна из причин краха попыток использования математических методов и компьютерных технологий в политологии, социологии и других областях, где сильно влияние человеческого фактора.

Выход из данного кризиса был предложен профессором университета г. Беркли (Калифорния, США) Лотфи Заде (Lotfi Zadeh) в 1965 году: в его пионерской работе [11] введено понятие *нечеткого множества*. Основная идея Л. Заде заключалась в том, чтобы «разрешить» характеристической функции множества принимать не только значения 0 (полная непринадлежность) или 1 (полная принадлежность), но и промежуточные значения принадлежности из отрезка $[0, 1]$. Таким образом, им было заменено понятие характеристической функции на понятие функции принадлежности

$$\mu_A : U \rightarrow [0, 1]. \quad (1)$$

Итак, нечеткое множество — это пара $\{U, \mu_A\}$, где U называется универсальным множеством, μ_A — функцией принадлежности.

Рассмотрим множество $F(U)$ нечетких подмножеств универсального множества U . В нем также можно ввести операции пересечения, объединения и дополнения. Заде предложил использовать следующие формализации этих операций:

$$\mu_{A \cap B}(u) = \min\{\mu_A(u), \mu_B(u)\}, \quad (2)$$

$$\mu_{A \cup B}(u) = \max\{\mu_A(u), \mu_B(u)\}, \quad (3)$$

$$\mu_{\neg A}(u) = 1 - \mu_A(u). \quad (4)$$

Нетрудно видеть, что если мы заменим в (2)–(4) функции принадлежности на характеристические функции множеств, то получим в точности определение соответствующих операций в классической теории множеств.

Можно ли ввести в нечетких множествах другие формализации операций пересечения, объединения и дополнения так, чтобы при замене функций принадлежности на характеристические функции мы получили бы общепринятые в теории множеств операции?

Ответ на этот вопрос положительный, например:

$$\mu_{A \cap B}(u) = \mu_A(u) \cdot \mu_B(u), \quad (5)$$

$$\mu_{A \cup B}(u) = \mu_A(u) + \mu_B(u) - \mu_A(u) \cdot \mu_B(u), \quad (6)$$

$$\mu_{\neg A}(u) = 1 - \mu_A(u). \quad (7)$$

Заметим, что существует много других подобных обобщений, отличных от представленных выше. К настоящему времени сформировалось представление о наиболее общей форме операторов пересечения и объединения в классе так называемых треугольных норм и конорм.

Треугольной нормой (сокращенно *t-нормой*) называется двухместная действительная функция $T : [0, 1] \times [0, 1] \rightarrow [0, 1]$, удовлетворяющая следующим условиям:

- $T(0, 0) = 0$, $T(\mu_A, 1) = T(1, \mu_A) = \mu_A$ (ограниченность);
- $T(\mu_A, \mu_B) = T(\mu_B, \mu_A)$ (коммутативность);
- $T(\mu_A, T(\mu_B, \mu_C)) = T(T(\mu_A, \mu_B), \mu_C)$ (ассоциативность);
- $T(\mu_A, \mu_B) \leq T(\mu_C, \mu_D)$, если $\mu_A \leq \mu_C$, $\mu_B \leq \mu_D$ (монотонность).

Простыми случаями треугольных норм являются операции (2), (5) и другие, например,

$$T_m(\mu_A, \mu_B) = \max\{0, \mu_A + \mu_B - 1\},$$

$$T_w(\mu_A, \mu_B) = \begin{cases} \mu_A, & \text{если } \mu_B = 1 \\ \mu_B, & \text{если } \mu_A = 1 \\ 0, & \text{иначе.} \end{cases}$$

Треугольной конормой (сокращенно *t-конормой*) называется двухместная действительная функция $\perp : [0, 1] \times [0, 1] \rightarrow [0, 1]$, удовлетворяющая следующим условиям:

- $\perp(1, 1) = 1$, $\perp(0, \mu_A) = \perp(\mu_A, 0) = \mu_A$ (ограниченность);
- $\perp(\mu_A, \mu_B) = \perp(\mu_B, \mu_A)$ (коммутативность);
- $\perp(\mu_A, \perp(\mu_B, \mu_C)) = \perp(\perp(\mu_A, \mu_B), \mu_C)$ (ассоциативность);
- $\perp(\mu_A, \mu_B) \geq \perp(\mu_C, \mu_D)$, если $\mu_A \geq \mu_C$, $\mu_B \geq \mu_D$ (монотонность).

Простыми случаями треугольных конорм являются операции (3), (6) и другие, например,

$$\perp_m(\mu_A, \mu_B) = \min\{1, \mu_A + \mu_B\},$$

$$\perp_w(\mu_A, \mu_B) = \begin{cases} \mu_A, & \text{если } \mu_B = 0 \\ \mu_B, & \text{если } \mu_A = 0 \\ 1, & \text{иначе.} \end{cases}$$

Используя нечеткие множества, мы можем определять различные понятия в более естественном для человеческого способа восприятия и описания объектов виде.

Лингвистические переменные

Дальнейшим шагом Заде стало введение понятия *нечеткой переменной* [1] как тройки вида:

$$\langle A, U, \mu_A(u) \rangle, \quad (8)$$

где A — наименование (имя) нечеткой переменной;

U — универсальное множество (область определения);

$\mu_A(u)$ — ограничения на возможные значения (смысл) переменной A .

Таким образом, нечеткая переменная — это поименованное нечеткое множество.

Лингвистическая переменная [1] представляет собой пятерку

$$\langle A, T(A), U, G, M \rangle, \quad (9)$$

где A — наименование (имя) лингвистической переменной;

$T(A)$ — терм-множество лингвистической переменной A , то есть множество ее лингвистических значений;

U — универсальное множество, в котором определяются значения лингвистической переменной A ;

G — синтаксическое правило, порождающее значения лингвистической переменной A (часто имеет форму грамматики);

M — семантическое правило, которое ставит в соответствие каждому элементу $T(A)$ его «смысл» как нечеткое подмножество U .

Пример лингвистической переменной «Quantity» представлен на рис. 9.

Полные ортогональные семантические пространства

Рассмотрим t нечетких переменных с именами a_1, a_2, \dots, a_t , заданных на одном универсальном множестве (рис. 10). Будем называть такую совокупность *семантическим пространством* s_t .

Введем систему ограничений для функций принадлежности нечетких переменных, составляющих s_t . Будем для простоты обозначать функцию принадлежности a_j через μ_j . Будем считать, что:

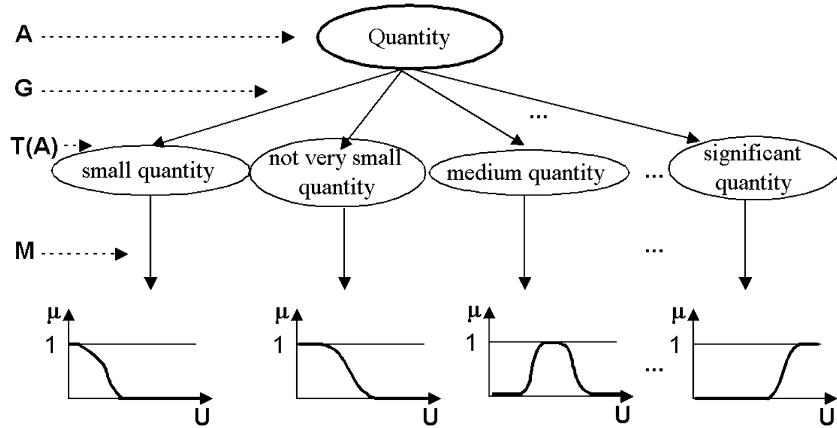


Рис. 9. Пример лингвистической переменной.




Рис. 10. Пример семантического пространства.

- 1) $\forall \mu_j, (1 \leq j \leq t), \exists U_j^1 \neq \emptyset$, где $U_j^1 = \{u \in U : \mu_j = 1\}$, U_j^1 есть отрезок или точка;
- 2) $\forall j, (1 \leq j \leq t), \mu_j$ не убывает слева от U_j^1 и не возрастает справа от U_j^1 (так как, согласно 1, U_j^1 является отрезком или точкой, понятия «слева» и «справа» определяются однозначно).
Требования 1 и 2 довольно естественны для функций принадлежности понятий, образующих семантическое пространство. Действительно, первое означает, что для любого используемого понятия в универсальном множестве существует хотя бы один объект, который является эталонным для данного понятия. Если таких эталонов много, то они расположены рядом, а не «рас-

киданы» по универсуму. Второе требование означает, что если объекты «близки» в смысле метрики в универсальном множестве, то они также «близки» в смысле принадлежности к некоторому понятию.

Далее нам понадобится наряду с функциями принадлежности использовать и характеристические функции, поэтому потребуем выполнения следующего технического условия:

- 3) $\forall j, (1 \leq j \leq t), \mu_j$ имеет не более двух точек разрыва первого рода.

Будем для простоты обозначать требования 1 – 3 через **L**.

Введем также систему ограничений для совокупностей функций принадлежности нечетких переменных, образующих s_t . А именно, будем считать, что:

- 4) $\forall u \in U \exists j (1 \leq j \leq t) : \mu_j(u) > 0$;

- 5) $\forall u \in U \sum_{j=1}^t \mu_j(u) = 1$.

Требования 4 и 5 также имеют довольно естественную интерпретацию. Требование 4, называемое *полнотой*, означает, что для любого объекта из универсального множества существует хотя бы одно понятие, к которому он может принадлежать. Это означает, что в нашем семантическом пространстве нет «дырок». Требование 5, называемое *ортогональностью*, означает, что мы не допускаем использования семантически близких понятий или синонимов, требуем достаточной различимости используемых понятий. Отметим также, что это требование часто выполняется или нет в зависимости от используемого метода построения функций принадлежности понятий, образующих семантическое пространство. Так, например, если у нас есть некоторое количество экспертов, мы им предъявляем объект $u \in U$ и допускаем только ответы «Да, $u \in a_j$ » и «Нет, $u \notin a_j$ » (ответ «Не знаю» не допускается), а в качестве значения функции принадлежности $\mu_j(u)$ берем отношение числа экспертов, ответивших положительно, к общему числу экспертов, то данное требование выполняется автоматически. Заметим также, что все приводимые ниже результаты справедливы при некотором ослаблении требования ортогональности [4], но

для его описания необходимо введение ряда дополнительных понятий. Поэтому мы остановимся на этом требовании.

Будем для простоты обозначать требования 4, 5 через G .

Будем называть семантическое пространство, состоящее из нечетких переменных, функции принадлежности которых удовлетворяют требованиям 1 – 3, а их совокупности — требованиям 4 и 5, полным *ортгональным семантическим пространством* и обозначать его $G(L)$.

Итак, в приложении 1 нами описан краткий минимум основных понятий, необходимых для создания теоретической модели и программно-математического обеспечения для решения задач информационного мониторинга.

Список литературы

- [1] Заде Л.А. Понятие лингвистической переменной и его применение к принятию приближенных решений. М.: Мир, 1976.
- [2] Рыжов А.П. Об агрегировании информации в нечетких иерархических системах // Интеллектуальные системы. Т. 6. Вып. 1–4. М., 2002. С. 341–364.
- [3] Рыжов А.П. О задаче информационного мониторинга сложных процессов // Тезисы докладов XI Международной конференции «Проблемы теоретической кибернетики». Ульяновск, июнь 1996. С. 173–174.
- [4] Рыжов А.П. О степени нечеткости размытых характеристик // Математическая кибернетика и ее приложения в биологии / Под ред. Л.В. Крушинского, С.В. Яблонского, О.Б. Лупанова. М.: МГУ, 1987. С. 60–77.
- [5] Рыжов А.П., Рогожин С.В. О нечетко заданных классах функций k -значной логики // V Всероссийская конференция «Нейрокомпьютеры и их применение». Сборник докладов. М., 17–19 февраля 1999. С. 460–463.
- [6] Рыжов А.П., Федорова М.С. Генетические алгоритмы в задаче выбора операторов агрегирования информации в системах

информационного мониторинга // V Всероссийская конференция «Нейрокомпьютеры и их применение». Сборник докладов. М., 17–19 февраля 1999. С. 267–270.

- [7] Рыжов А.П. Элементы теории нечетких множеств и измерения нечеткости. М.: Диалог-МГУ, 1998.
- [8] Саати Т. Анализ иерархических процессов. М.: Радио и связь, 1993.
- [9] Ryjov A., Belenki A., Hooper R., Pouchkarev V., Fattah A., Zadeh L. Development of an Intelligent System for Monitoring and Evaluation of Peaceful Nuclear Activities (DISNA). IAEA, STR-310. Vienna, 1998.
- [10] Ryjov A.P. Fuzzy Linguistic Scales: Properties and Applications // Soft Computing in Measurement and Information Acquisition / Ed. by L. Reznik, V. Kreinovich. Springer-Verlag, 2003. P. 23–38.
- [11] Zadeh L.A. Fuzzy sets // Information and Control. 1965. V. 8. P. 338–353.
- [12] Альбицкий В.Ю., Никольский Л.А., Абросимов М.Ю. Фетоинфантальные потери (причины и пути снижения). Казань: Медицина, 1997.
- [13] Лопухин Ю.М. Неинвазивные методы определения эпидермального холестерина в диагностике атеросклероза. М.: ГЭОТАРМЕДИЦИНА, 1999.
- [14] Лопухин Ю.М., Маркин С.С. Атеросклероз, холестериноз // Эфферентная медицина. М., 1989.
- [15] Жукоцкий А.В., Строгалов А.С., Коган Э.М., Николаева Е.А., Анисимов М.П., Якубова Н.И. О проблеме объективизации цитологической диагностики с помощью оптоэлектронных систем (морфоденситометрический метод) // Интеллектуальные системы. Т. 3. Вып. 3–4. М., 1998. С. 233–247.
- [16] Жукоцкий А.В., Конаков В.Ф., Коган Э.М. Патент RU2104528: Способ определения состояния биологического материала. 1998.

- [17] Жукоцкий А.В., Якубова Н.И., Акимжанов Р.Х., Кюрдюкова Е.В. Применение персональных компьютеров в морфологической диагностике. Методические указания. М., 1991.
- [18] International Handbook of Cardiovascular Risk (prevention and management) / ed. Th.F. Luscher. France: Euromed Communications Ltd, 2002.