

УДК 004.8
ББК 32.81
К48

К48 Луис Энрике Сукар

Вероятностные графовые модели. Принципы и приложения / пер. с англ. А. Снастин. – М.: ДМК Пресс, 2020. – 338 с.: ил.

ISBN 978-5-97060-874-6

В настоящее время вероятностные графовые модели широко распространены как мощная и вполне сформировавшаяся методика для выполнения умозаключений и выводов в условиях неопределенности. В отличие от некоторых узкоспециализированных методик, применявшихся в ранних экспертных системах, вероятностные графовые модели основаны на строгих математических принципах теории графов и теории вероятности. Эта книга на современном уровне охватывает более широкий диапазон вероятностных графовых моделей, чем другие недавно опубликованные материалы в этой области: разнообразные классификаторы, скрытые марковские модели, марковские случайные поля, байесовские сети и их динамические, временные и причинно-следственные варианты, реляционные вероятностные графовые модели, графы решений и марковский процесс принятия решений. В книге представлены эти вероятностные графовые модели и соответствующие методы логического вывода и обучения в ясном и доступном стиле. Автор делится своим богатым опытом, накопленным в процессе активной практической работы в области использования вероятностных графовых моделей, и демонстрирует примеры их применения в разнообразных областях реальной деятельности: от биоинформатики до задач наблюдения за загрязнением воздуха и распознавания объектов.

Книга предназначена для студентов старших курсов и аспирантов, а также для ученых-исследователей и инженеров-практиков, работающих в других отраслях и интересующихся применением вероятностных моделей.

First published in English under the title Concise Computer Vision; Copyright © Springer-Verlag London, 2015. This edition has been translated and published under licence from Springer-Verlag London Ltd., part of Springer Nature. Springer-Verlag London Ltd., part of Springer Nature takes no responsibility and shall not be made liable for the accuracy of the translation. © 2020 by DMK Press. All rights reserved.

Все права защищены. Любая часть этой книги не может быть воспроизведена в какой бы то ни было форме и какими бы то ни было средствами без письменного разрешения владельцев авторских прав.

Материал, изложенный в данной книге, многократно проверен. Но, поскольку вероятность технических ошибок все равно существует, издательство не может гарантировать абсолютную точность и правильность приводимых сведений. В связи с этим издательство не несет ответственности за возможные ошибки, связанные с использованием книги.

ISBN 978-1-4471-6698-6 (англ.)
ISBN 978-5-97060-874-6 (рус.)

© Springer-Verlag London, 2015
© Оформление, перевод на русский язык, издание,
ДМК Пресс, 2020

Оглавление

| | |
|---|-----------|
| Предисловие от издательства | 11 |
| Вступительное слово..... | 12 |
| Предисловие..... | 14 |
| Благодарности..... | 18 |
| Список сокращений, принятых в книге..... | 20 |
| Условные математические обозначения, используемые в книге | 23 |
| Часть I. Теоретические основы | 25 |
| Глава 1. Введение..... | 26 |
| 1.1 Неопределенность..... | 26 |
| 1.1.1 Воздействие неопределенности | 26 |
| 1.2 Краткая история | 27 |
| 1.3 Основные вероятностные модели | 28 |
| 1.3.1 Пример | 31 |
| 1.4 Вероятностные графовые модели | 33 |
| 1.5 Представление, логический вывод и обучение | 35 |
| 1.6 Приложения | 37 |
| 1.7 Обзор содержимого книги | 38 |
| 1.8 Материалы для дополнительного чтения | 39 |
| Ссылки на источники..... | 39 |
| Глава 2. Теория вероятностей | 41 |
| 2.1 Введение | 41 |
| 2.2 Основные правила | 43 |
| 2.3 Случайные переменные..... | 45 |
| 2.3.1 Двумерные случайные переменные | 49 |
| 2.4 Теория информации | 50 |
| 2.5 Материалы для дополнительного чтения..... | 53 |
| 2.6 Задания и упражнения | 53 |
| Ссылки на источники..... | 54 |
| Глава 3. Теория графов..... | 56 |
| 3.1 Определения..... | 56 |
| 3.2 Типы графов | 57 |
| 3.3 Пути и циклы | 58 |
| 3.4 Изоморфизм графов | 60 |
| 3.5 Деревья..... | 60 |
| 3.6 Клики | 63 |
| 3.7 Полное упорядочивание..... | 64 |
| 3.8 Алгоритмы упорядочивания и триангуляции..... | 66 |
| 3.8.1 Поиск паросочетания максимальной мощности..... | 66 |

| | |
|--|------------|
| 3.8.2 Дополнение графа..... | 66 |
| 3.9 Материалы для дополнительного чтения..... | 67 |
| 3.10 Задания и упражнения..... | 68 |
| Ссылки на источники..... | 69 |
| Часть II. Вероятностные модели..... | 71 |
| Глава 4. Байесовские классификаторы | 72 |
| 4.1 Введение | 72 |
| 4.1.1 Оценки классификатора..... | 73 |
| 4.2 Байесовский классификатор..... | 74 |
| 4.2.1 Наивный байесовский классификатор..... | 75 |
| 4.3 Другие модели: TAN, BAN | 79 |
| 4.4 Частично наивные байесовские классификаторы..... | 80 |
| 4.5 Многомерные байесовские классификаторы..... | 84 |
| 4.5.1 Многомерные классификаторы на основе байесовских сетей..... | 85 |
| 4.5.2 Байесовские классификаторы на основе цепи..... | 86 |
| 4.6 Иерархическая классификация | 88 |
| 4.6.1 Оценка цепного пути | 89 |
| 4.7 Приложения | 91 |
| 4.7.1 Визуальное определение кожи человека на изображениях..... | 91 |
| 4.7.2 Выбор лекарственных средств для лечения вируса иммунодефицита человека..... | 94 |
| 4.8 Материалы для дополнительного чтения..... | 96 |
| 4.9 Задания и упражнения..... | 96 |
| Ссылки на источники..... | 97 |
| Глава 5. Скрытые марковские модели | 100 |
| 5.1 Введение | 100 |
| 5.2 Марковские цепи..... | 101 |
| 5.2.1 Оценка параметров..... | 104 |
| 5.2.2 Сходимость..... | 105 |
| 5.3 Скрытые марковские модели | 106 |
| 5.3.1 Вычисление оценки..... | 109 |
| 5.3.2 Оценка состояния..... | 111 |
| 5.3.3 Обучение..... | 114 |
| 5.3.4 Расширения | 116 |
| 5.4 Приложения | 118 |
| 5.4.1 Алгоритм PageRank..... | 118 |
| 5.4.2 Распознавание жестов | 119 |
| 5.5 Материалы для дополнительного чтения..... | 122 |
| 5.6 Задания и упражнения..... | 122 |
| Ссылки на источники..... | 123 |
| Глава 6. Марковские случайные поля | 125 |
| 6.1 Введение | 125 |
| 6.2 Марковские сети..... | 127 |

| | |
|--|------------|
| 6.2.1 Регулярные марковские случайные поля..... | 129 |
| 6.3 Случайные поля Гиббса | 130 |
| 6.4 Логический вывод | 131 |
| 6.5 Оценка параметров | 133 |
| 6.5.1 Оценка параметров с помощью данных с метками | 134 |
| 6.6 Условные случайные поля..... | 135 |
| 6.7 Приложения | 137 |
| 6.7.1 Сглаживание изображений..... | 137 |
| 6.7.2 Расширенная аннотация изображений | 139 |
| 6.8 Материалы для дополнительного чтения | 142 |
| 6.9 Задания и упражнения | 143 |
| Ссылки на источники..... | 144 |
| Глава 7. Байесовские сети: представление и логический вывод | 146 |
| 7.1 Введение..... | 146 |
| 7.2 Представление | 147 |
| 7.2.1 Структура..... | 148 |
| 7.2.2 Параметры..... | 152 |
| 7.3 Логический вывод..... | 158 |
| 7.3.1 Односвязные сети: алгоритм распространения доверия..... | 160 |
| 7.3.2 Многосвязные сети | 165 |
| 7.3.3 Приближенный логический вывод..... | 174 |
| 7.3.4 Наиболее вероятное объяснение | 177 |
| 7.3.5 Непрерывные переменные | 178 |
| 7.4 Приложения..... | 180 |
| 7.4.1 Валидация информации | 180 |
| 7.4.2 Анализ надежности..... | 185 |
| 7.5 Материалы для дополнительного чтения | 187 |
| 7.6 Задания и упражнения..... | 188 |
| Ссылки на источники..... | 189 |
| Глава 8. Байесовские сети: обучение..... | 191 |
| 8.1 Введение | 191 |
| 8.2 Обучение параметров | 191 |
| 8.2.1 Сглаживание..... | 192 |
| 8.2.2 Неопределенность параметров..... | 192 |
| 8.2.3 Недостаточный объем данных..... | 194 |
| 8.2.4 Дискретизация..... | 198 |
| 8.3 Обучение структуры | 200 |
| 8.3.1 Обучение дерева..... | 200 |
| 8.3.2 Обучение полидерева..... | 203 |
| 8.3.3 Методики поиска с оценкой..... | 204 |
| 8.3.4 Методики проверки независимости | 211 |
| 8.4 Объединение экспертных знаний и имеющихся данных | 212 |
| 8.5 Приложения | 213 |
| 8.5.1 Модель загрязнения воздуха в Мехико-сити | 214 |

| | | |
|-------------------|--|------------|
| 8.6 | Материалы для дополнительного чтения..... | 217 |
| 8.7 | Задания и упражнения..... | 217 |
| | Ссылки на источники..... | 219 |
| Глава 9. | Динамические и временные байесовские сети..... | 221 |
| 9.1 | Введение..... | 221 |
| 9.2 | Динамические байесовские сети..... | 222 |
| 9.2.1 | Логический вывод..... | 223 |
| 9.2.2 | Обучение..... | 224 |
| 9.3 | Временные сети событий..... | 226 |
| 9.3.1 | Байесовские сети с временными узлами..... | 226 |
| 9.4 | Приложения..... | 233 |
| 9.4.1 | Динамические байесовские сети: распознавание жестов..... | 233 |
| 9.4.2 | Байесовская сеть с временными узлами: прогнозирование вариантов мутаций ВИЧ..... | 238 |
| 9.5 | Материалы для дополнительного чтения..... | 242 |
| 9.6 | Задания и упражнения..... | 242 |
| | Ссылки на источники..... | 243 |
| Часть III. | Модели принятия решений..... | 245 |
| Глава 10. | Графы принятия решений..... | 246 |
| 10.1 | Введение..... | 246 |
| 10.2 | Теория принятия решений..... | 247 |
| 10.2.1 | Основы теории принятия решений..... | 247 |
| 10.3 | Деревья решений..... | 251 |
| 10.4 | Диаграммы влияния..... | 254 |
| 10.4.1 | Моделирование..... | 254 |
| 10.4.2 | Оценка..... | 256 |
| 10.4.3 | Расширения..... | 261 |
| 10.5 | Приложения..... | 262 |
| 10.5.1 | Медработник, принимающий теоретические решения..... | 262 |
| 10.6 | Материалы для дополнительного чтения..... | 266 |
| 10.7 | Задания и упражнения..... | 266 |
| | Ссылки на источники..... | 268 |
| Глава 11. | Марковские процессы принятия решений..... | 269 |
| 11.1 | Введение..... | 269 |
| 11.2 | Моделирование..... | 270 |
| 11.3 | Вычисление оценки..... | 273 |
| 11.3.1 | Итерация значения..... | 273 |
| 11.3.2 | Итерация стратегии..... | 274 |
| 11.4 | Факторизованные марковские процессы принятия решений..... | 275 |
| 11.4.1 | Абстракция..... | 277 |
| 11.4.2 | Декомпозиция..... | 278 |
| 11.5 | Частично наблюдаемые марковские процессы принятия решений..... | 279 |
| 11.6 | Приложения..... | 280 |

| | |
|---|------------|
| 11.6.1 Управление электростанцией..... | 280 |
| 11.6.2 Согласование задач робота..... | 283 |
| 11.7 Материалы для дополнительного чтения..... | 289 |
| 11.8 Задания и упражнения..... | 289 |
| Ссылки на источники..... | 291 |
| Часть IV. Реляционные и причинно-следственные модели..... | 293 |
| Глава 12. Реляционные вероятностные графовые модели..... | 294 |
| 12.1 Введение..... | 294 |
| 12.2 Логика..... | 296 |
| 12.2.1 Логика высказываний..... | 296 |
| 12.2.2 Логика предикатов первого порядка..... | 297 |
| 12.3 Вероятностные реляционные модели..... | 300 |
| 12.3.1 Логический вывод..... | 302 |
| 12.3.2 Обучение..... | 302 |
| 12.4 Марковские логические сети..... | 302 |
| 12.4.1 Логический вывод..... | 304 |
| 12.4.2 Обучение..... | 305 |
| 12.5 Приложения..... | 306 |
| 12.5.1 Моделирование студента..... | 306 |
| 12.6 Вероятностная реляционная модель студента..... | 307 |
| 12.6.1 Визуальные грамматики..... | 310 |
| 12.7 Материалы для дополнительного чтения..... | 312 |
| 12.8 Задания и упражнения..... | 313 |
| Ссылки на источники..... | 314 |
| Глава 13. Графовые причинно-следственные модели..... | 316 |
| 13.1 Введение..... | 316 |
| 13.2 Причинно-следственные байесовские сети..... | 318 |
| 13.3 Обоснование причин..... | 320 |
| 13.3.1 Прогноз..... | 320 |
| 13.3.2 Контрфактуальный анализ..... | 322 |
| 13.4 Обучение причинно-следственных моделей..... | 323 |
| 13.5 Приложения..... | 325 |
| 13.5.1 Обучение причинно-следственной модели для синдрома дефицита внимания и гиперактивности..... | 325 |
| 13.6 Материалы для дополнительного чтения..... | 327 |
| 13.7 Задания и упражнения..... | 327 |
| Ссылки на источники..... | 328 |
| Словарь терминов..... | 329 |
| Предметный указатель..... | 333 |

Предисловие от издательства

Отзывы и пожелания

Мы всегда рады отзывам наших читателей. Расскажите нам, что вы думаете об этой книге – что понравилось или, может быть, не понравилось. Отзывы важны для нас, чтобы выпускать книги, которые будут для вас максимально полезны.

Вы можете написать отзыв на нашем сайте www.dmkpress.com, зайдя на страницу книги и оставив комментарий в разделе «Отзывы и рецензии». Также можно послать письмо главному редактору по адресу dmkpress@gmail.com; при этом укажите название книги в теме письма.

Если вы являетесь экспертом в какой-либо области и заинтересованы в написании новой книги, заполните форму на нашем сайте по адресу http://dmkpress.com/authors/publish_book/ или напишите в издательство по адресу dmkpress@gmail.com.

Скачивание исходного кода примеров

Скачать файлы с дополнительной информацией для книг издательства «ДМК Пресс» можно на сайте www.dmkpress.com на странице с описанием соответствующей книги.

Список опечаток

Хотя мы приняли все возможные меры для того, чтобы обеспечить высокое качество наших текстов, ошибки все равно случаются. Если вы найдете ошибку в одной из наших книг – возможно, ошибку в основном тексте или программном коде, – мы будем очень благодарны, если вы сообщите нам о ней. Сделав это, вы избавите других читателей от недопонимания и поможете нам улучшить последующие издания этой книги.

Если вы найдете какие-либо ошибки в коде, пожалуйста, сообщите о них главному редактору по адресу dmkpress@gmail.com, и мы исправим это в следующих тиражах.

Нарушение авторских прав

Пиратство в интернете по-прежнему остается насущной проблемой. Издательства «ДМК Пресс» и Springer очень серьезно относятся к вопросам защиты авторских прав и лицензирования. Если вы столкнетесь в интернете с незаконной публикацией какой-либо из наших книг, пожалуйста, пришлите нам ссылку на интернет-ресурс, чтобы мы могли применить санкции.

Ссылку на подозрительные материалы можно прислать по адресу электронной почты dmkpress@gmail.com.

Мы высоко ценим любую помощь по защите наших авторов, благодаря которой мы можем предоставлять вам качественные материалы.

Вступительное слово

Вероятностные графовые модели и методы их использования для разумных рассуждений и выводов в условиях неопределенности появились в 1980-х гг. в сообществах, занимающихся проблемами статистических выводов и искусственного интеллекта. Конференция по неопределенности в области искусственного интеллекта (UAI – Uncertainty in Artificial Intelligence) стала самым первым форумом, посвященным этой быстро развивающейся области исследований. На этой конференции UAI в 1992 году в Сан Хосе (San Jose) я впервые встретила Энрике Сукара (Enrique Sucar) – тогда мы оба были аспирантами, – он представлял свою работу по реляционным и временным (темпоральным) моделям для систем высокоуровневой обработки компьютерного зрения. За прошедшие с тех пор 25 лет Энрике внес впечатляющий вклад в эту область исследований: от фундаментальной работы по объективной вероятности до разработки усовершенствованных форм вероятностных графовых моделей, таких как временные байесовские сети и байесовские сети для вычисления вероятности событий, а также методики обучения вероятностных графовых моделей, например самая последняя работа Энрике по классификаторам типа байесовская цепь для многомерной классификации.

В настоящее время вероятностные графовые модели широко распространены как мощная и вполне сформировавшаяся методика для выполнения умозаключений и выводов в условиях неопределенности. В отличие от некоторых узкоспециализированных методик, применявшихся в ранних экспертных системах, вероятностные графовые модели основаны на строгих математических принципах теории графов и теории вероятности. Их можно использовать для широкого диапазона задач, связанных с выводом и обоснованием результатов, в том числе задач прогнозирования, мониторинга, диагностики, оценки рисков и принятия решений. Существует множество эффективных алгоритмов как для логического вывода, так и для обучения, доступных в виде программного обеспечения с открытым исходным кодом и коммерческих программных продуктов. Более того, мощь и эффективность этих алгоритмов уже подтверждена их успешным практическим применением в огромном диапазоне областей задач реального окружающего нас мира. Энрике Сукар стал главным специалистом по практическому внедрению и утверждению вероятностных графовых моделей как эффективной и полезной технологии с учетом его работы в широком диапазоне прикладных областей. Это медицина, реабилитация и здравоохранение в целом, робототехника и машинное зрение, образование, анализ надежности и разнообразные промышленные приложения – от нефтедобычи до энергетики.

Первыми авторами, которые начали исследования байесовских сетей и с большим мастерством убедительно описали их в книгах, стали Джуда Перл (Judea Pearl) с книгой «Probabilistic Reasoning in Intelligent Systems» и Рич Неаполитан (Rich Neapolitan) с книгой «Probabilistic Reasoning in Expert Systems». Предлагаемая читателям монография Энрике Сукара представляет собой своевременное дополнение к комплекту литературы, изданной после книг Перла и Неаполитана. Эта книга на современном уровне охватывает более широкий диапазон вероятностных графовых моделей, чем другие недавно опубликованные материалы в этой области: разнообразные классификаторы, скрытые марковские модели, марковские случайные поля, байесовские сети и их динамические, временные и причинно-следственные варианты, реляционные вероятностные графовые модели, графы решений и марковский процесс принятия решений. В книге представлены эти вероятностные графовые модели и соответствующие методы логического вывода и обучения в ясном и доступном стиле. Поэтому книга издание подходит для студентов старших курсов и аспирантов, а также для ученых-исследователей и инженеров-практиков, работающих в других отраслях и интересующихся применением вероятностных моделей. В этой книге Энрике делится своим богатым опытом, накопленным в процессе активной практической работы в области использования вероятностных графовых моделей, и демонстрирует примеры их применения в разнообразных областях реальной деятельности: от биоинформатики до задач наблюдения за загрязнением воздуха и распознавания объектов. Я искренне поздравляю Энрике с выходом этой книги и настоятельно рекомендую ее будущим читателям.

Энн Е. Николсон,
Мельбурн, Австралия,
май 2015 года

Предисловие

О чем эта книга

Вероятностные графовые модели уже превратились в мощный набор методик, используемых в нескольких предметных областях. В этой книге представлен общий вводный курс по вероятностным графовым моделям (probabilistic graphical models – PGM) с учетом их применения в инженерных дисциплинах. Здесь подробно рассматриваются главные принципы основных классов вероятностных графовых моделей: байесовские классификаторы, скрытые марковские модели, байесовские сети, динамические и временные байесовские сети, марковские случайные поля, диаграммы влияния и марковские процессы принятия решений. Кроме того, описано представление, процесс логического вывода и принципы обучения для всех этих методик. В книге также рассматриваются реальные приложения для каждого типа модели.

Некоторые характерные особенности этой книги:

- основные классы вероятностных графовых моделей представлены в одной монографии в единой универсальной рабочей среде;
- книга охватывает основополагающие принципы: представление, процесс логического вывода и процесс обучения для всех методов;
- демонстрируются практические приложения различных методик для решения реальных задач, что весьма важно для студентов, аспирантов и инженеров-практиков;
- в книгу включены некоторые самые последние разработки в этой области, такие как многомерные байесовские классификаторы, реляционные графовые модели и причинно-следственные модели;
- к каждой главе прилагается ряд упражнений и заданий, которые могут послужить отправным пунктом для исследовательских и программных проектов.

Одна из целей этой книги – стимулирование практического приложения вероятностных графовых моделей к реальным задачам. Такой подход требует не только теоретических знаний о различных моделях и методиках, но также некоторого практического опыта и знания предметной области. Чтобы помочь профессионалам в различных областях получить некоторое углубленное представление об использовании вероятностных графовых моделей для решения практических задач, в книгу включено множество примеров применения разнообразных типов моделей для широкого диапазона предметных областей, в том числе:

- компьютерное зрение;
- биомедицинские приложения;
- промышленные приложения;
- извлечение информации;
- интеллектуальные обучающие системы;
- биоинформатика;
- приложения в области охраны окружающей среды;
- робототехника;
- взаимодействие человек–компьютер;
- проверка достоверности информации;
- уход за пациентами (медицина).

Для кого предназначена эта книга

Эта книга может использоваться как учебное пособие для студентов последнего года обучения и аспирантов по курсу вероятностных графовых моделей для изучающих информатику, инженерное дело, физику и т. д. Книга также может служить справочником для профессионалов, которым необходимо применять вероятностные графовые модели в различных областях, и для всех, кто хочет овладеть основами применения этих методик.

Для чтения данной книги не требуется какой-либо особенной предварительной подготовки, тем не менее желательно знание основ теории вероятностей и статистики. Предполагается, что читатель обладает базовыми знаниями математики на уровне средней школы, а также имеет определенный уровень подготовки в области информатики и программирования. Упражнения и задания по программированию требуют некоторых знаний и практического опыта использования какого-либо языка программирования, например C, C++, Java, Matlab и т. д.

Упражнения и задания

К каждой главе (за исключением введения) прилагается ряд упражнений и заданий. Некоторые из них являются вопросами и задачами, способствующими более глубокому пониманию концепций и методик, изложенных в соответствующей главе. Кроме того, в каждой главе предлагается несколько заданий, представляющих собой отправные пункты для исследовательских и программных проектов (такие задания отмечены тремя звездочками «***»), которые могут использоваться как учебные курсовые проекты.

Обзор содержимого книги

Книга разделена на четыре части. В первой части представлено общее введение и обоснование использования вероятностных графовых моделей, приведены необходимые для чтения основы теории вероятностей и тео-

рии графов. Во второй части описываются модели, которые не считаются решениями или утилитами: байесовские классификаторы, скрытые марковские модели, марковские случайные поля, байесовские сети, динамические и временные байесовские сети. Третья часть начинается с краткого введения в теорию решений, затем рассматриваются модели с поддержкой принятия решений, включая деревья решений, диаграммы влияния и марковские процессы принятия решений. В четвертой части представлены два расширения стандартных вероятностных графовых моделей: реляционные вероятностные графовые модели и причинно-следственные вероятностные графовые модели.

Зависимости между содержанием глав показаны на рис. 1. Дуга от главы X к главе Y , т. е. $X \rightarrow Y$, означает, что изучение содержания главы X требуется (или, по меньшей мере, рекомендуется) для понимания главы Y . Такое графическое представление структуры книги дает немалый объем информации в аналоговом представлении о графовых моделях, которые будут рассматриваться в этой книге.

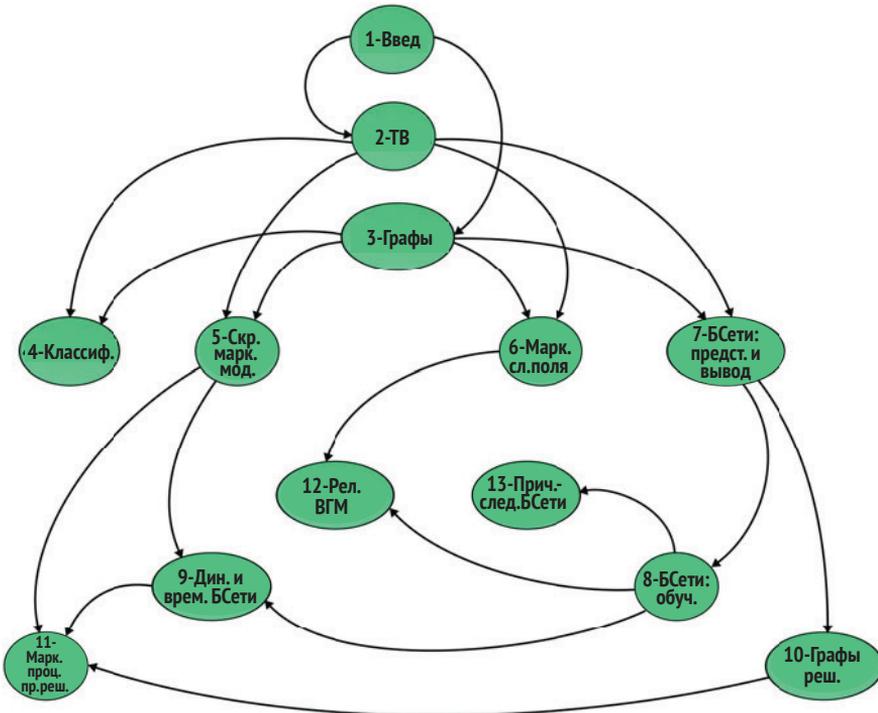


Рис. 1. Структура книги в виде направленного ациклического графа, показывающего, какие главы требуется изучить для перехода к следующим главам

По рис. 1 можно определить несколько различных способов чтения данной книги. В первую очередь рекомендуется прочитать введение и главы о математических основах 2 и 3. Затем более или менее незави-

симо друг от друга можно изучать различные модели в части II: классификацию (глава 4), скрытые марковские модели (глава 5), марковские случайные поля (глава 6) и байесовские сети (главы 7–9). Перед чтением главы об обучении байесовских сетей (глава 8) необходимо прочитать главу 7 – представление и логический вывод, кроме того, изучение обеих этих глав требуется перед переходом к динамическим и временным байесовским сетям.

Темы в частях III и IV требуют изучения некоторых глав из части II. Для чтения главы 10, в которой рассматриваются деревья решений и диаграммы влияния, вы должны как минимум прочитать первую главу по байесовским сетям. Перед чтением главы 11 о последовательном принятии решений рекомендуется изучить скрытые марковские модели, а также динамические и временные байесовские сети. Реляционные вероятностные графовые модели (глава 12) основаны на марковских случайных полях и байесовских сетях, поэтому требуется предварительное изучение глав 6 и 8. Наконец, причинно-следственные модели в главе 13 также основаны на байесовских сетях, включая методики их обучения.

Если в учебном курсе недостаточно времени для полного охвата материала всей книги, то можно предложить несколько альтернативных вариантов. Например, сосредоточиться на вероятностных моделях без рассмотрения теории принятия решений или более продвинутых расширений, т. е. изучать части I и II. Другой вариант – все внимание уделить моделям принятия решений, включая часть I, необходимые подготовительные главы из части II и часть III. Кроме того, вы можете запланировать курс по своему усмотрению, но непременно с учетом зависимостей, показанных на графе на рис. 1. Но если вы располагаете достаточным временем и имеете серьезные намерения, то я предлагаю прочесть всю книгу в порядке глав. Желаю успеха.

Луис Энрике Сукар (Luis Enrique Suca),
Пуэбла, Мексика,
февраль 2015 г.

Часть I

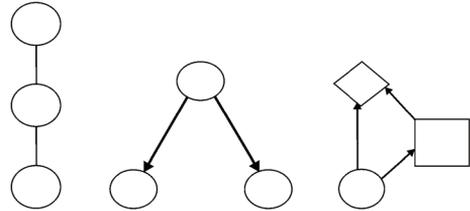


Теоретические основы

Первые главы книги содержат общую вводную информацию по вероятностным графовым моделям и излагают теоретические основы, необходимые для чтения остальной части книги, – теорию вероятности и теорию графов.

Глава 1

Введение



1.1 Неопределенность

Для достижения своих целей интеллектуальные агенты (сущности), естественные или искусственные, должны выбирать образ действий из многих возможных вариантов. То есть они должны принимать решение на основе информации, получаемой из окружающей среды, накопленных ранее знаний и конкретных целей (задач). Во многих случаях информация и знания неполные или ненадежные, поэтому результаты этих решений являются неопределенными, т. е. агенты должны принимать решения в условиях неопределенности. Например, врач скорой помощи должен действовать очень быстро, даже если располагает недостаточной информацией о состоянии пациента. Самоуправляемое транспортное средство, определяющее возможные препятствия на своем пути, должно принимать решение о повороте или остановке, не зная точно об удаленности, размере и скорости объекта, препятствующего движению. Финансист должен выбрать наилучший вариант инвестирования в соответствии со своими приблизительными прогнозами ожидаемого оборота средств и дохода при различных альтернативных вариантах и в соответствии с требованиями своих клиентов.

Одна из целей искусственного интеллекта – разработка систем, которые способны обосновывать и принимать решения в условиях неопределенности. Обоснование в условиях неопределенности представляло трудную задачу для первых интеллектуальных систем, так как привычные парадигмы и принципы не очень хорошо подходили для управления неопределенностью.

1.1.1 Воздействие неопределенности

Первые системы искусственного интеллекта были основаны на классической логике, в которой знания можно представить как набор логи-

ческих высказываний или правил. Такие системы обладали двумя важными свойствами: *модульностью* и *монотонностью*, которые помогают упростить получение знаний и логические выводы из них.

Система является *модульной*, если каждый элемент знаний может использоваться независимо для получения логических заключений (выводов). Таким образом, если предпосылки любого логического высказывания (условия) или правила являются истинными, то мы можем получить (вывести) соответствующее заключение без необходимости рассмотрения других элементов базы знаний. Например, если существует правило $\forall X, \text{паралич}(X) \rightarrow \text{повреждена_рука}(X)$, тогда если известно, что у *Мери* был паралич, то известно также, что у нее повреждена рука.

Система является *монолитной*, если ее знания всегда расширяются монотонно, т. е. любой дедуктивно выводимый факт или заключение сохраняет свою силу, даже если системе становятся известны новые факты. Например, если в системе существует правило $\forall X, \text{птица}(X) \rightarrow \text{летает}(X)$, тогда если *Твити* – птица, то можно сделать вывод, что она летает.

Но если имеется неопределенность этих двух свойств, то в общем случае они не являются истинными. В медицинских системах обычно существует неопределенность диагноза для пациента, так что даже если пациент перенес паралич, возможно, его рука не повреждена. Это зависит от конкретного участка мозга, пораженного параличом. Не все птицы летают, поэтому если в дальнейшем мы узнаем, что *Твити* – пингвин, то необходимо *отменить* заключение о том, что он(а) летает.

Неточность описанных выше пар свойств усложняет систему, которая должна обосновывать выводы и заключения в условиях неопределенности. Теоретически такая система должна учитывать все доступные знания и факты при выводе заключения, а кроме того, непременно должна обладать способностью изменять свои выводы и заключения при получении новых данных.

1.2 Краткая история

В истории искусственного интеллекта можно выделить следующие стадии развития методик управления неопределенностью:

- *начальная стадия* (1950-е и 1960-е гг.) – исследователи искусственного интеллекта (ИИ) сосредоточены на решении таких задач, как доказательство теорем, игра в шахматы и подобные игры, а также область задач планирования «мир многогранников», в которые не включалась неопределенность. Таким образом, не было необходимости в разработке методик управления неопределенно-

стью. В начальной стадии развития ИИ преобладающей являлась символическая парадигма;

- *ad-hoc-методики* (1970-е гг.) – разработка экспертных систем для реальных приложений, например для медицины и горнодобывающей промышленности, потребовала развития методик управления неопределенностью. Новейшие на тот момент ad-hoc-методики разрабатывались для специализированных экспертных систем, например фактор определенности MYCIN [15] и псевдовероятности Prospector [3]. Позже выяснилось, что эти методики содержали набор неявных предположений, которые ограничивали их применимость [5]. Кроме того, в этот период предлагались альтернативные теории управления неопределенностью в экспертных системах, в том числе нечеткая логика (fuzzy logic) [17] и теория Демпстера–Шафера [14];
- *возрождение вероятности* (1980-е гг.) – теория вероятности использовалась в некоторых ранних экспертных системах, но несколько позже от нее отказались, так как применение теории вероятности в ее простейших формах приводило к высокой сложности вычислений (см. раздел 1.3). Новые разработки, в особенности байесовские сети [11], предоставляют возможность создавать сложные вероятностные системы эффективным способом. Таким образом, на этом этапе начинается новая эра в управлении неопределенностью в области ИИ;
- *разнотипный (теоретический) формализм* (1990-е гг.) – продолжается развитие байесовских сетей, кроме того, они объединяются с разработками эффективных алгоритмов логического вывода и обучения. В то же время и другие методики, такие как нечеткая логика и немонотонная логика, рассматриваются как альтернативные варианты обоснования выводов и заключений в условиях неопределенности;
- *вероятностные графовые модели* (2000-е гг.) – несколько методик, основанных на теории вероятности и представлениях в форме графов, объединяются, образуя мощные методы представления, обоснования и принятия решений в условиях неопределенности. В их числе байесовские сети, марковские сети, диаграммы влияния, марковские процессы принятия решения и другие.

1.3 Основные вероятностные модели

Теория вероятности предоставляет прочную основу для управления неопределенностью, следовательно, вполне естественно воспользоваться теорией вероятности для обоснования выводов и заключений в

условиях неопределенности. Но если применять теорию вероятности в ее простейшей форме для решения сложных задач, то очень скоро нас остановит проблема сложности вычислений.

В этом разделе показано, как можно смоделировать задачу, используя простейший вероятностный метод, основанный на равномерном представлении, а также как можно воспользоваться этим представлением для ответа на некоторые вероятностные запросы. Это поможет лучше понять ограничения такого простейшего метода и объяснит причины, стимулирующие разработку вероятностных графовых моделей.¹

Многие задачи можно сформулировать в виде набора (множества) переменных X_1, X_2, \dots, X_n , при этом мы знаем значения некоторых переменных, тогда как другие неизвестны. Например, в медицинской диагностике переменные могут представлять определенные симптомы и соответствующие болезни. Обычно нам известны конкретные симптомы, и необходимо определить (найти) наиболее вероятную болезнь (или болезни). Другим примером может послужить разработка в финансовой сфере системы, которая помогает принять решение о сумме кредита, выдаваемого конкретному клиенту. В этом случае значимыми переменными являются атрибуты (характеристики) этого клиента, т. е. возраст, доходы, ранее выданные кредиты и т. д., а также переменная, содержащая сумму выдаваемого кредита. На основе атрибутов (характеристик) конкретного клиента необходимо определить, например, максимальную сумму кредита, которую можно предоставить этому клиенту без особого риска. Вообще говоря, существует несколько типов задач, которые можно смоделировать таким способом, – это задачи диагностики, классификации, распознавания и некоторые другие.

В вероятностной рабочей среде можно считать, что каждый атрибут задачи представляет собой случайную переменную, так что есть возможность получить определенное значение из набора (множества) значений.² Будем считать, что это множество возможных значений является конечным, например $X = \{x_1, x_2, \dots, x_m\}$ может представлять m возможных заболеваний в области медицинской диагностики. Каждое значение случайной переменной будет иметь определенную вероятность, связанную с внутренним контекстом. В рассматриваемом здесь примере случайной переменной X это может быть вероятность возникновения каждого заболевания в определенной группе населения (это называют частотой заболеваний или просто заболеваемостью), т. е. $P(X = x_1), P(X = x_2), \dots$, или в сокращенной форме $P(x_1), P(x_2), \dots$.

Если рассматриваются две случайные переменные X и Y , то можно вычислить вероятность получения определенного значения переменной X и вероятность получения определенного значения переменной Y ,

¹ В этом и в следующих разделах предполагается, что читатель знаком с некоторыми основными концепциями теории вероятности. Обзор этих и других концепций приведен в главе 2.

² Формальное определение случайной переменной будет дано несколько позже.

т. е. $P(X = x_i \wedge Y = y_j)$ или просто $P(x_i, y_j)$. Это называют совместной вероятностью переменных X и Y . Данный принцип можно обобщить для n случайных переменных, где совместная вероятность обозначается как $P(X_1, X_2, \dots, X_n)$. Можно интерпретировать выражение $P(X_1, X_2, \dots, X_n)$ как функцию, которая присваивает значение вероятности всем возможным сочетаниям значений переменных X_1, X_2, \dots, X_n .

Таким образом, можно представить любую предметную область как:

- 1) множество случайных переменных X_1, X_2, \dots, X_n ;
- 2) совместное распределение вероятностей, связанное с этими переменными, $P(X_1, X_2, \dots, X_n)$.

Приняв такое представление, можно ответить на некоторые запросы с учетом значений конкретных переменных в рассматриваемой предметной области, например:

- *частное (или маргинальное) распределение вероятностей* – вероятность одной из переменных принимает конкретное значение. Это можно вычислить, суммируя значения всех остальных переменных из совместного распределения вероятностей. Другими словами, $P(X_i) = \sum_{\forall X \neq X_i} P(X_1, X_2, \dots, X_n)$. Это называют маргинализацией. Маргинализацию можно обобщить для получения частного распределения вероятностей некоторого подмножества переменных путем суммирования значений всех остальных переменных;
- *условные вероятности* – по определению условная вероятность X_i с учетом того, что нам известно значение X_j , равна $P(X_i | X_j) = P(X_i, X_j) / P(X_j)$, $P(X_j) \neq 0$. Значения $P(X_i, X_j)$ и $P(X_j)$ можно получить с помощью маргинализации и с помощью этих значений вычисляются условные вероятности;
- *полная абдукция* – средняя ошибка в процентах (MPE) – если подмножество (E) переменных известно, то абдукция заключается в поиске значений остальных переменных (J), которые максимизируют условную вероятность, давая обоснование, $\max P(J | E)$. Таким образом, $\text{ArgMax}_J [P(X_1, X_2, \dots, X_n) / P(E)]$;
- *частичная абдукция* – оценка апостериорного максимума (MAP) – в этом случае существуют три подмножества переменных: обоснование E , запрашиваемые переменные, которые необходимо максимизировать, J и остальные переменные K , так что необходимо максимизировать $P(J | E)$. Результат получается путем маргинализации на подмножестве K и максимизации на подмножестве J , т. е. $\text{ArgMax}_J [\sum_{X \in K} P(X_1, X_2, \dots, X_n) / P(E)]$.

Кроме того, если имеются данные из интересующей нас предметной области, то можно получить модель по этим данным, т. е. оценку совместного распределения вероятностей для значимых переменных.

В следующем разделе рассматривается простой пример применения базовой методики.

1.3.1 Пример

Воспользуемся обычным примером определения возможности игры в гольф для демонстрации простой методики. В этой задаче имеется пять переменных: прогноз погоды, температура, влажность, ветер, игра. В табл. 1.1 показаны некоторые данные для этого примера. Все переменные дискретные, так что они могут содержать значения из конечного множества возможных значений, например прогноз может быть одним из следующих: солнечно, облачно или дождь. Теперь рассмотрим, как можно выполнить описанные выше различные вероятностные запросы для этого примера.

Таблица 1.1. Выборка данных для примера определения возможности игры в гольф

| Прогноз | Температура | Влажность | Ветер | Игра |
|----------|-------------|------------|--------|------|
| Солнечно | Высокая | Высокая | Ложь | Нет |
| Солнечно | Высокая | Высокая | Истина | Нет |
| Облачно | Высокая | Высокая | Ложь | Да |
| Дождь | Средняя | Высокая | Ложь | Да |
| Дождь | Низкая | Нормальная | Ложь | Да |
| Дождь | Низкая | Нормальная | Истина | Нет |
| Облачно | Низкая | Нормальная | Истина | Да |
| Солнечно | Средняя | Высокая | Ложь | Нет |
| Солнечно | Низкая | Нормальная | Ложь | Да |
| Дождь | Средняя | Нормальная | Ложь | Да |
| Солнечно | Средняя | Нормальная | Истина | Да |
| Облачно | Средняя | Высокая | Истина | Да |
| Облачно | Высокая | Нормальная | Ложь | Да |
| Дождь | Средняя | Высокая | Истина | Нет |

Сначала упростим пример, используя только две переменные – Прогноз и Температура. По данным из табл. 1.1 можно вычислить совместное распределение вероятностей для Прогноза и Температуры, как показа-

но в табл. 1.2. Каждая запись (строка) табл. 1.2 соответствует совместному распределению вероятностей $P(\text{Прогноз}, \text{Температура})$, например $P(\text{Прогноз} = C, \text{Температура} = B) = 0.143$.

Таблица 1.2. Совместное распределение вероятностей для переменных Прогноз и Температура

| Прогноз | Температура | | |
|---------|-------------|-------|-------|
| | В | С | Н |
| С | 0.143 | 0.143 | 0.071 |
| О | 0.143 | 0.071 | 0.071 |
| Д | 0 | 0.214 | 0.143 |

Сначала получим частное (маргинальное) распределение вероятностей для этих двух переменных. Если выполнить суммирование по строкам (маргинализация переменной Температура), то получим частное распределение вероятностей для переменной Прогноз $P(\text{Прогноз}) = [0.357, 0.286, 0.357]$. Если просуммировать столбцы, то получим частное распределение вероятностей для переменной Температура $P(\text{Температура}) = [0.286, 0.428, 0.286]$. Из вычисленных распределений получаем, что наиболее вероятной температурой является С (средняя), а для прогноза наиболее вероятны значения С (солнечно) и Д (дождь).

Теперь можно вычислить условные вероятности для переменной Прогноз при заданной температуре и для переменной Температура при заданном прогнозе. Например:

$$P(\text{Температура} \mid \text{Прогноз} = Д) = \frac{P(\text{Температура} \wedge \text{Прогноз} = Д)}{P(\text{Прогноз} = Д)} = [0, 0.6, 0.4]$$

$$P(\text{Прогноз} \mid \text{Температура} = Н) = \frac{P(\text{Прогноз} \wedge \text{Температура} = Н)}{P(\text{Температура} = Н)} = [0.25, 0.25, 0.5]$$

С учетом вычисленных распределений при прогнозе дождливой погоды наиболее вероятной является средняя температура, а при низкой температуре наиболее вероятно прогнозирование дождя.

Наконец, наиболее вероятным сочетанием значений переменных Прогноз и Температура является {Дождь, Средняя}. Это сочетание в данном примере можно получить непосредственно из таблицы совместного распределения вероятностей.

Несмотря на возможность выполнения разнообразных вероятностных запросов для этого небольшого примера, описанная выше методика становится неприемлемой для сложных задач с многочисленными переменными, так как размер таблицы и объем прямых вычислений

частных и условных вероятностей возрастает экспоненциально при увеличении числа переменных в модели.

Еще один недостаток этой простейшей методики состоит в том, что для получения правильных оценок совместного распределения вероятностей по данным потребуется очень большая база данных, если количество переменных в модели велико. Существует простое практическое правило: число экземпляров (записей) как минимум в 10 раз больше числа возможных сочетаний значений переменных в модели, так что если рассматривается 50 бинарных переменных, то потребуется не менее 10×2^{50} экземпляров (записей в базе данных).

Кроме того, таблица совместного распределения вероятностей дает слишком мало информации о задаче человеку, т. е. эта методика имеет еще и ограничения по восприятию и пониманию (когнитивности).

Перечисленные выше недостатки рассматриваемой в этом разделе простейшей методики являются одним из стимулов развития вероятностных графовых моделей.

1.4 Вероятностные графовые модели

Вероятностные графовые модели (ВГМ) предоставляют рабочую среду для управления неопределенностью на основе теории вероятности с выполнением вычислений наиболее эффективным способом. Основная идея состоит в рассмотрении только тех отношений независимости, которые являются действительными и обоснованными для конкретной задачи, и включении только этих отношений в вероятностную модель для уменьшения сложности по критериям требований к объему памяти и времени вычислений. Естественным способом представления отношений зависимости и независимости во множестве переменных является использование графов. Переменные, которые связаны прямой зависимостью, соединяются ребрами (дугами), а отношения независимости неявно присутствуют в таком графе зависимостей.

Вероятностная графовая модель – это компактное представление совместного распределения вероятностей, из которого можно получить частное распределение вероятностей и условные вероятности. Вероятностная графовая модель обладает следующими преимуществами по сравнению с простым традиционным представлением:

- в общем гораздо более компактная модель (по объему памяти);
- в общем гораздо более эффективная модель (по времени вычислений);
- проще для понимания и получения информации;
- проще для обучения на различных формах данных или для создания на основе экспертных знаний.

Вероятностная графовая модель определяется двумя компонентами:

- 1) граф $G(V, E)$, который определяет структуру модели;
- 2) набор локальных функций $f(Y_i)$, которые определяют параметры, где Y_i – подмножество X .

Совместное распределение вероятностей вычисляется как произведение локальных функций:

$$P(X_1, X_2, \dots, X_N) = K \prod_{i=1}^M f(Y_i) \quad (1.1)$$

где K – константа нормализации (приводит сумму вероятностей к единице).

Такое представление в форме графа и набор локальных функций (называемых потенциальными функциями) является основой для логического вывода и обучения в ВГМ.

Логический вывод (inference): получение частного распределения вероятностей или условных вероятностей на любом подмножестве переменных Z с учетом любого другого подмножества Y .

Обучение: при заданном наборе данных – значений переменной X (набор может быть неполным) определяется оценка структуры (графа) и параметров (локальных функций) модели.

Вероятностные графовые модели можно классифицировать по следующим трем характеристикам:

- 1) направленные или ненаправленные (ориентированные или неориентированные);
- 2) статические или динамические;
- 3) вероятностные или предназначенные для принятия решений.

Первая характеристика определяет тип графа, используемого для представления отношений зависимости. Ненаправленные (неориентированные) графы представляют симметричные отношения, тогда как направленные (ориентированные) графы представляют отношения, в которых направление важно. В заданном множестве случайных переменных с соответствующими условными отношениями зависимостей невозможно представить все отношения с помощью одного типа графа [11], следовательно, необходимы оба типа моделей.

Вторая характеристика определяет, представляет ли модель множество переменных в конкретный момент времени (статическая модель) или в течение различных интервалов времени (динамическая модель). Вероятностные модели включают только случайные переменные, а модели для принятия решений также содержат параметры принятия решения и переменные полезности.

Самые распространенные классы ВГМ и их типы в соответствии с приведенной выше классификацией перечислены в табл. 1.3.

Таблица 1.3. Основные типы вероятностных графовых моделей

| Тип модели | Направленный / Ненаправленный граф | Статическая / Динамическая | Вероятностная / Для принятия решений |
|---|--|-------------------------------|--|
| Байесовские классификаторы | Напр. / Ненапр. | Статическая | Вероятностная |
| Марковские цепи | Напр. | Динамическая | Вероятностная |
| Скрытые марковские модели | Напр. | Динамическая | Вероятностная |
| Марковские случайные поля | Ненапр. | Статическая | Вероятностная |
| Байесовские сети | Напр. | Статическая | Вероятностная |
| Динамические байесовские сети | Напр. | Динамическая | Вероятностная |
| Диаграммы влияния | Напр. | Статическая | Для принятия решений |
| Марковские процессы принятия решений (МППР) | Напр. | Динамическая | Для принятия решений |
| Частично наблюдаемые МППР | Напр. | Динамическая | Для принятия решений |

Все эти типы моделей будут подробно рассматриваться в следующих главах. Кроме того, будут также описаны некоторые расширения, которые считаются более выразительными моделями (реляционные вероятностные графовые модели) или представляют причинно-следственные отношения (причинно-следственные байесовские сети).

1.5 Представление, логический вывод и обучение

Для каждого класса вероятностной графовой модели существуют три аспекта: представление, логический вывод и обучение.

Представление (representation) – это основное свойство каждой модели, которое определяет, какие сущности (объекты) образуют модель и как эти сущности связаны между собой. Например, все вероятностные графовые модели могут быть представлены как графы, которые определяют структуру модели, и локальные функции, описывающие

параметры модели. Но тип графа и локальные функции различны для разных типов моделей.

Логический вывод (inference) заключается в ответах на разнообразные вероятностные запросы и основан на самой модели и некотором доказательстве (подтверждении). Например, получение апостериорного распределения вероятностей переменной или набора переменных, при условии что другие переменные в этой модели известны. Главная трудность – как сделать это эффективно.

Для создания таких моделей существует два основных способа: создание «вручную» с помощью экспертов в рассматриваемой предметной области или вывод модели методом индукции из данных. В последние годы особое внимание уделялось методике вывода модели методом индукции на основе методик машинного обучения, поскольку создание модели с помощью экспертов представляет собой сложную и дорогостоящую задачу. В частности, определение параметров для моделей обычно выполняется на основе данных, так как люди склонны давать неудачные критерии оценки вероятностей.

Важным свойством этих методик с практической прикладной точки зрения является возможность отделения процессов логического вывода и методик обучения от модели. Таким образом, как и в других представлениях методик искусственного интеллекта, таких как логика и правила вывода, механизмы обоснования (доказательства) являются общими и могут применяться к различным моделям. В результате методики, разработанные для вероятностного логического вывода в каждом классе вероятностных графовых моделей, можно напрямую применять для различных моделей в разнообразных приложениях.

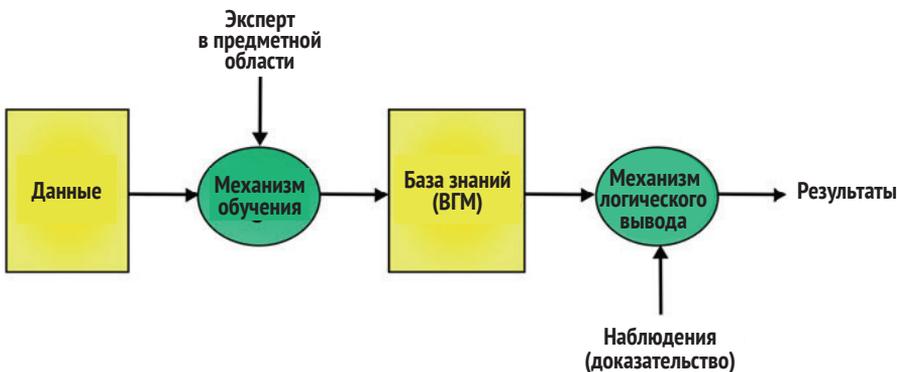


Рис. 1.1. Схематическое представление общего принципа, которому подчиняются различные классы ВГМ: четкое разделение обобщенных механизмов обучения и логического вывода и базы знаний, зависящей от конкретного приложения

Этот главный теоретический принцип схематически показан на рис. 1.1. На основе данных, или знаний эксперта, или сочетания обо-

их источников база знаний – в данном случае вероятностная графовая модель создается с использованием механизма обучения. После создания модели можно применять ее для выполнения вероятностного обоснования с помощью механизма логического вывода. Механизм логического вывода на основе наблюдений и самой модели извлекает результаты. Механизмы обучения и логического вывода являются общими для любого класса вероятностной графовой модели, поэтому могут применяться для моделирования и обоснования в различных предметных областях.

Для каждого типа вероятностной графовой модели, представленной в этой книге, сначала будет описано ее представление, затем будут рассматриваться некоторые из наиболее часто используемых методик логического вывода и обучения.

1.6 Приложения

В большинстве реальных задач подразумевается работа в условиях неопределенности, и в таких задачах обычно существует большое количество факторов или переменных, которые необходимо учитывать при решении. Вероятностные графовые модели формируют идеальную рабочую среду для решения сложных задач в условиях неопределенности, поэтому могут применяться в широком диапазоне предметных областей, включая следующие:

- медицинская диагностика и принятие решений;
- определение местонахождения, навигация и планирование действий мобильного роботизированного устройства;
- диагностика сложного промышленного оборудования, например турбин и оборудования электростанций;
- моделирование пользователем адаптивных интерфейсов и интеллектуальных обучающих средств;
- распознавание речи и обработка естественных языков;
- моделирование и прогнозирование загрязнения окружающей среды;
- анализ надежности и устойчивости сложных процессов;
- моделирование эволюционирования вирусов;
- распознавание объектов в системах компьютерного зрения;
- извлечение информации;
- рынки энергоресурсов.

Для различных приложений в большей или меньшей степени подходят те или иные типы вероятностных графовых моделей, как будет показано в следующих главах, где представлены примеры приложений для каждого класса вероятностных графовых моделей.

1.7 Обзор содержимого книги

Книга разделена на четыре части.

В части I изложены математические основы для изучения и понимания моделей и методик, представленных в последующих главах. Глава 2 содержит обзор некоторых основных концепций теории вероятностей и теории информации, наиболее важных для понимания вероятностных графовых моделей. В главе 3 приводится общий обзор теории графов с выделением некоторых аспектов, которые важны для представления и логического вывода в вероятностных графовых моделях, – рассматриваются клики, хордальные (триангулированные) графы, совершенная упорядоченность и т. п.

В части II описаны различные типы вероятностных моделей, которые содержат только случайные переменные, но в этих моделях не рассматривается принятие решений или полезность. Это самая большая часть книги, которая включает описание следующих типов вероятностных графовых моделей:

- байесовские классификаторы;
- марковские цепи и скрытые марковские модели;
- марковские случайные поля;
- байесовские сети;
- динамические байесовские сети и временные сети.

Каждый тип модели рассматривается в отдельной главе (за исключением байесовских сетей, описание которых разделено на две главы), включая представление, логический вывод и обучение, а также примеры практических приложений.

В части III представлены модели, реализующие принятие решений и оценивающие полезность, поэтому основное внимание уделяется помощи механизма принятия решений для определения оптимальных действий в условиях неопределенности. Эта часть содержит две главы. В первой главе рассматриваются методики моделирования для выбора одного или нескольких решений, включая деревья решений и диаграммы влияния. Вторая глава посвящена последовательному принятию решений, в особенности марковским процессам принятия решений.

В части IV рассматриваются другие теоретические принципы, которые можно считать расширениями обычных вероятностных графовых моделей. В этой части также две главы. В первой главе рассматриваются реляционные вероятностные модели, которые увеличивают мощность представления стандартных вероятностных графовых моделей, объединяя выразительную мощь логики первого порядка с возможностями объяснения и обоснования неопределенности вероятностных моделей. Во второй главе представлены причинно-следственные графовые мо-

дели, которые существенно усиливают представление вероятностных зависимостей для выражения отношений причин и следствий (результатов).

1.8 Материалы для дополнительного чтения

В этой книге тема вероятностных графовых моделей рассматривается в широком аспекте. Некоторые другие книги не менее подробно освещают эту тему. Коллер (Koller) и Фридман (Friedman) [7] представляют модели различной структуры, уделяя меньше внимания приложениям. В книге Лауритцена (Lauritzen) [8] в большей степени рассматривается статистический аспект. Байесовское программирование [1] предоставляет другой подход к реализации графовых моделей на основе парадигмы программирования.

Кроме того, существует несколько книг, в которых более подробно рассматривается один или несколько типов моделей: байесовские сети [2, 10, 11], графы решений [6], марковские случайные поля [9], марковские процессы принятия решений [13], реляционные вероятностные модели [4] и причинно-следственные модели [12, 16].

Ссылки на источники

1. Bessiere, P., Mazer, E., Ahuactzin, J. M., Mekhnacha, K. Bayesian Programming. CRC Press, Boca Raton (2014).
2. Darwiche, A. Modeling and Reasoning with Bayesian Networks. Cambridge University Press, New York (2009).
3. Duda, R. O., Hart, P. A., Nilsson, N. L. Subjective Bayesian methods for rule-based inference systems. In: Proceeding of the National Computer Conference, vol. 45, p. 1075–1082 (1976).
4. Getoor, L., Taskar, B. Introduction to Statistical Relational Learning. MIT Press, Cambridge (2007).
5. Heckerman, D. Probabilistic interpretations for MYCIN's certainty factors. In: Proceedings of the First Conference on Uncertainty in Artificial Intelligence (UAI), p. 9–20 (1985).
6. Jensen, F. V. Bayesian Networks and Decision Graphs. Springer, New York (2001).
7. Koller, D., Friedman, N. Probabilistic Graphical Models: Principles and Techniques. MIT Press, Cambridge (2009).
8. Lauritzen, S. L. Graphical Models. Oxford University Press, Oxford (1996).

10. Li, S. Z. *Markov Random Field Modeling in Image Analysis*. Springer, London (2009).
11. Neapolitan, R. E. *Probabilistic Reasoning in Expert Systems*. Wiley, New York (1990).
12. Pearl, J. *Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference*. Morgan Kaufmann, San Francisco (1988).
13. Pearl, J. *Causality. Models, Reasoning and Inference*. Cambridge University Press, New York (2009).
14. Puterman, M. L. *Markov Decision Processes: Discrete Stochastic Dynamic Programming*. Wiley, New York (1994).
15. Shafer, G. *A Mathematical Theory of Evidence*. Princeton University Press, Princeton (1976).
16. Shortliffe, E. H., Buchanan, B. G. A model of inexact reasoning in medicine. *Math. Biosci.* 23, 351–379 (1975).
17. Spirtes, P., Glymour, C., Scheines, R. *Causation, Prediction, and Search*. MIT Press, New York (2000).
18. Zadeh, L. A. Knowledge Representation in Fuzzy Logic. *IEEE Trans. Knowl. Data Eng.* 1 (1), 89–100 (1989).