

Българска академия на науките
Институт по математика и информатика
Секция „Алгебра и логика“



Изкуствен интелект – дефиниция, реализация и последствия

Какво е това, как да го направим и какво ще правим,
след като го направим?

Дисертационен труд

на

Димитър Димитров Добрев

по професионално направление „Математика“ (4.5)
научна специалност „Математическа логика“

Научен ръководител: доц. д-р Любомир Иванов

София, 2024

Дисертацията съдържа 115 страници, от които 6 страници уводни раздели, 103 страници основен текст и 6 страници заключителен материал, включително библиография с 92 заглавия.

Съдържание

Увод.....	7
1 Какво е изкуствен интелект?.....	11
1.1 Неформална дефиниция.....	11
1.1.1 ИИ – Какво е това?.....	11
1.2 Формална дефиниция.....	13
1.2.1 Дефиниция на ИИ и програма, която удовлетворява тази дефиниция.....	13
1.2.2 Въведение.....	14
1.2.3 Литературен обзор.....	16
1.2.3.1 Генерален интелект.....	16
1.2.3.2 Интуитивна дефиниция.....	16
1.2.3.3 Една дискусия.....	18
1.2.3.4 Естествен интелект.....	21
1.2.3.5 Логическо мислене.....	21
1.2.3.6 Формална дефиниция.....	22
1.2.3.7 Първо подобрене.....	23
1.2.3.8 Допълнителни параметри.....	24
1.2.3.9 Второ подобрене.....	25
1.2.3.10 Алтернативно мнение.....	25
1.2.3.11 Какво се случва в момента?.....	25
1.2.4 Постановка на задачата.....	26
1.2.5 Оценка.....	27
1.2.6 Очакваната оценка.....	28
1.2.7 Най-добрата стратегия.....	28
1.2.8 Дефиниция на ИИ.....	31
1.2.9 Програма, удовлетворяваща дефиницията.....	31
1.2.10 Толеранс.....	33
1.2.11 Дали това е ИИ?.....	34
1.2.12 Свят със случайност.....	34
1.2.13 Дефиниция със случайност.....	35
1.2.14 Програма със случайност.....	35
1.2.15 Свят с много агенти.....	36
1.2.16 Заключение.....	37
1.2.17 Благодарности.....	37
2 Как да го направим?.....	38
2.1 Език за описание на светове.....	38
2.2 Въведение.....	38
2.3 Играта шах.....	40

2.3.1	Шах с един играч.....	41
2.3.2	Цел.....	41
2.4	Литературен обзор.....	42
2.4.1	<i>Markov decision process</i>	42
2.4.2	<i>Situation Calculus</i>	42
2.5	Жизнен опит.....	43
2.5.1	Живот.....	43
2.5.2	Евристика.....	44
2.5.3	Атомарна формула.....	45
2.5.4	Моментно събитие.....	46
2.5.5	Предположение.....	46
2.5.6	Дефиниция на живот.....	46
2.6	<i>Event-Driven</i> модели.....	47
2.6.1	Вероятностен интервал.....	48
2.6.2	Възможно, но невероятно.....	48
2.6.3	Статистика.....	48
2.6.4	Дефиниция на <i>ED</i> модел.....	49
2.6.5	Интерпретация.....	50
2.6.6	Характеристика.....	51
2.6.7	Примери.....	52
2.7	Събития.....	53
2.7.1	Видими събития.....	54
2.7.2	Съставни събития.....	54
2.7.3	Невидими събития.....	55
2.7.3.1	Винаги се случва.....	55
2.7.3.2	Ще се случи.....	56
2.7.3.3	Ще се случи с вероятност p	56
2.7.3.4	Достижимо събитие.....	56
2.7.3.5	Тестово събитие.....	57
2.7.4	Състояние на <i>ED</i> модел.....	57
2.7.5	Полувидими събития.....	57
2.7.6	Нерелевантни събития.....	58
2.7.7	Литературен обзор.....	58
2.8	Свят.....	59
2.8.1	Минимален модел.....	60
2.8.2	Съвършен модел.....	60
2.8.3	Базов модел.....	61
2.8.4	<i>Simple MDP</i>	61
2.8.5	Фиксирана стратегия.....	62
2.8.6	Екстремна стратегия.....	62

2.8.7	От <i>MDP</i> към <i>Simple MDP</i>	63
2.8.8	Дефиниция на <i>Simple MDP</i>	63
2.8.9	<i>MDP</i> като <i>Simple MDP</i>	64
2.8.10	Начален <i>belief</i>	65
2.9	Интерпретация	65
2.9.1	Възможно бъдеще	66
2.9.2	Възможно минало.....	66
2.9.3	Минало vs Бъдеще.....	67
2.9.4	Свободна воля.....	68
2.9.5	Неподвижен <i>belief</i>	68
2.9.6	Обозрим свят	69
2.9.7	Единствен <i>belief</i>	69
2.9.8	Разширен модел.....	70
2.9.9	<i>MDP</i> като <i>ED</i> модел.....	72
2.9.9.1	Fully observable Markov decision process	72
2.9.9.2	Partially observable Markov decision process	73
2.9.10	Литературен обзор	74
2.10	Описание на играта шах.....	75
2.10.1	Компютърна емуляция	75
2.10.2	Използваме кодиране.....	75
2.10.3	Две празни действия	76
2.10.4	Едно, две, три	76
2.10.5	Следа	76
2.10.6	<i>Horizontal</i> и <i>Vertical</i>	77
2.10.7	Подвижна следа	79
2.11	Алгоритми	80
2.11.1	Какво е алгоритъм?.....	81
2.11.2	Алгоритъмът на фигурите.....	82
2.11.3	Алгоритмите на царя и на коня	82
2.11.4	Алгоритмите на топа и на офицера	83
2.11.5	Машината на Тюринг	85
2.11.6	Литературен обзор	87
2.12	Обекти.....	87
2.12.1	Свойства	87
2.12.2	Какво е обект.....	87
2.12.3	Второ кодиране	87
2.13	Шах с двама играчи.....	88
2.13.1	Детерминиран свят	89
2.13.2	Невъзможни събития	90
2.13.3	Втори агент.....	91

2.13.4	Собствено състояние	92
2.13.5	Неизчислимо правило.....	92
2.14	Агенти.....	94
2.14.1	Взаимодействие между агенти	94
2.14.2	Сигнали между агенти.....	94
2.14.3	Обмен на информация	95
2.14.4	Комуникационен интерфейс	95
2.14.5	Литературен обзор	96
2.15	По-нататъшна работа	96
2.16	Заклучение.....	96
3	Какво ще правим, след като го направим?.....	98
3.1	ИИ не трябва да е <i>Open Source Project</i>	98
3.1.1	Въведение	98
3.1.2	Какво може да се случи?.....	99
3.1.3	Можем ли да заключим звяра в клетка?.....	100
3.1.4	Принципа на моркова и тоягата	101
3.1.5	Можем ли да не създаваме ИИ?.....	101
3.1.6	Защо трябва да засекретим ИИ технологията?	102
3.1.7	Секретни списания	102
3.1.8	Сериозните списания	103
3.1.9	Заклучени компютри.....	104
3.1.10	Заклучение.....	104
3.2	Как ще изглежда животът ни след появата на ИИ?	106
	Заклучение	108
	Публикации	109
	Декларация	111
	Литература.....	112

Увод

Целта на тази дисертация е да разсее две заблуди, свързани с изкуствения интелект, и да зададе трите най-важни въпроса, свързани с тази тема. Двете заблуди са, че ИИ е функция без памет и че ИИ е псевдонаука. Трите въпроса, които ще разгледаме, са „Какво е ИИ?“, „Как да го създадем?“ и „Какви ще са последствията от създаването му?“.

Първата заблуда е, че ИИ е функция без памет. Тази заблуда се нарича *Full Observability*. Идеята е, че ИИ вижда всичко, което му е нужно, и няма смисъл да помни какво се е случило до момента. В литературата се споменава и за обратното, т.е. за *Partial Observability*, но по тази тема почти не се работи. Повечето автори приемат, че допускането на скрито състояние (памет) силно ще усложни задачата и ще я направи нерешима. Всъщност интересният случай е *Partial Observability* и отказът да се разглежда този случай е сериозна грешка.

Не сме точни, когато казваме, че повечето автори разглеждат ИИ като функция без памет. По-точно би било твърдението, че те приемат обучения ИИ като функция без памет. Може да се приеме, че ИИ е програмата, която търси обучения ИИ (т.е. която се обучава). Резултатът от обучението е обученият ИИ и въпросът, който ни интересува, е какво представлява обученият ИИ. Повечето автори разглеждат множество от двойки $\langle x, y \rangle$ (x е въпросът, а y е отговорът). На базата на това множество те търсят функция, която на всеки въпрос x връща съответния отговор y . Тази задача е известна като „интерполация на функция“. Задачата се нарича „невронни мрежи“, когато интерполиращата функция се търси в множеството на невронните мрежи.

Не искаме да подценим разработката на невронните мрежи. Този подход дава удивителни резултати, които го правят основния метод в областта на ИИ. Все пак невронните мрежи са ограничени от липсата на памет, което е съществен недостатък.

Тайната на ИИ се крие в скритото състояние на света. Ако се откажем от невидимата информация, ще пропуснем най-интересното. В основата на ИИ е „разбирането“ на света, а да разберем света, означава да го опишем чрез някакъв език за описание на светове. Затова в тази дисертация се говори толкова много за езици за описание на света. Описанието на скритото състояние не е еднозначно, защото има много възможни обяснения на света. Различните описания може да разглеждаме като различни хипотези и можем да правим експерименти, за да проверим коя е вярната хипотеза. Търсенето на различни описания (хипотези) можем да наречем „въображение“. Тоест ИИ без скрито състояние е ИИ без въображение.

Втората заблуда е, че ИИ е псевдонаука и че сериозните учени не трябва да се занимават с това. Става дума за истинския (генералния) изкуствен интелект. Повечето хора са убедени, че генералният изкуствен интелект е нещо невъзможно (нещо от научната фантастика). Когато стане дума за ИИ, повечето хора приемат, че се говори за слабия ИИ, който не е ИИ, а е имитация на ИИ. Самата идея за слаб ИИ е създадена от хора, които не вярват в истинския ИИ и са дълбоко убедени, че това е нещо напълно невъзможно.

Това е причината, поради която обществото гледа на работещите в областта на силния ИИ като на луди. Нас ни слагат в един куп заедно с търсачите на НЛО и изобретателите на перпетуум-мобиле. Аз самият приемам търсачите на перпетуум-мобиле за луди и не трябва да се сърдя, че и на мен се лепва този етикет.

Все пак в науката никоя идея не трябва да се отхвърля априори. Много неща са изглеждали невъзможни, но се е оказало, че просто още не им е дошло времето. Основната причина хората да не успяват да реализират една идея е това, че не вярват, че това е

възможно. В момента, в който повярват, те успяват много бързо да решат проблема. Обикновено виждат, че някой друг вече е реализирал идеята и те веднага повтарят неговия успех. Навремето хората са смятали, че машините никога няма да могат да играят шах. Сега програмата за игра на шах е нещо елементарно, което може да се обясни и напише за няколко часа (аз съм го правил в курса си по програмиране).

Заблудата, че сериозните учени не трябва да се занимават с ИИ, е сериозен проблем, защото това води до изоставане в тази област. Преди време подобна заблуда е имало спрямо кибернетиката, което е довело до сериозно изоставане в областта на компютрите (особено на страните от Източния блок).

Дори и сред специалистите по математическа логика има известен скептицизъм относно ИИ, а логиката е областта на математиката, която е най-близка и най-подходяща за създаването на ИИ. Може да се каже, че математиката е в основата на всички точни науки, а логиката е математиката на математиката. Всяка математическа дисциплина е изградена върху фундамента на логиката.

Логиката се занимава със същността на доказателството. Какво е доказателство? Това е начинът, по който хората мислят. Но защо само хората, машините също могат да мислят и да извършват доказателства. Затова логиката е най-близката област до ИИ и логиците са най-добре подготвените специалисти за извършване на сериозни изследвания в тази област.

За всяка задача си има специалисти, които са най-подготвени и най-подходящи за решаването ѝ. Ако искате картина, ще потърсите художник, ако искате песен, ще потърсите музикант. В програмирането най-добри се оказват математиците, защото тяхното формално и абстрактно мислене е много подходящо за писането на програми. За решаването на задачата ИИ най-подготвени са логиците, защото те са запознати с абстракцията на различните светове, на логическите формули и кога един свят е модел на една формула.

Първият въпрос е свързан с дефиницията на ИИ. Почти никой не задава този въпрос! Има огромен брой книги и статии, посветени на ИИ, но в тези книги и статии много рядко се задава въпросът „Какво е ИИ?“. Все пак, нека да отбележим две фундаментални публикации, където този въпрос е централен. Това са Wang (1995) и Hutter (2000). Ще отбележим и една обзорна статия написана в нашия институт (Angelova et al., 2021).

Интересна е дефиницията, дадена от Council of Europe (2022). Тя гласи:

AI is actually a young discipline of about sixty years, which brings together sciences, theories and techniques (including mathematical logic, statistics, probabilities, computational neurobiology and computer science) and whose goal is to achieve the imitation by a machine of the cognitive abilities of a human being.¹

Интересното в тази дефиниция е, че Съветът на Европа признава, че математическата логика е в основата на ИИ, макар че много от логиците не са съгласни с това.

Най-известната дефиниция на ИИ е дадена от Тюринг и това е „Тестът на Тюринг“ (Turing, 1950). Идеята е, че зад завеса са скрити човек и компютър, който имитира човек.

¹ ИИ всъщност е млада дисциплина от около шестдесет години, която обединява науки, теории и техники (включително математическа логика, статистика, теория на вероятностите, невробология и информатика), чиято цел е да постигне имитация на когнитивните способности на човека чрез машина.

Ако компютърът имитира човека достатъчно добре, така че да не можем да го отличим от човека, тогава това е ИИ. Дефиницията на Тюринг е много добра, но тя има един съществен недостатък. Това е дефиниция на обучен интелект, а ние искаме да дефинираме необучен интелект. Например новороденото бебе е интелект, но не е обучен интелект.

За да бъде отстранен този недостатък на дефиницията на Тюринг, беше създадена една неформална дефиниция на ИИ (Dobrev, 2000). Тя гласи следното: **„ИИ ще наричаме такава програма, която в произволен свят би се справила не по-зле от човек“**.

Тази дефиниция беше публикувана в популярен вид в научно-популярно списание и тази публикация е включена като част от дисертацията (параграф 1.1) По късно същата дефиниция беше публикувана в научно списание (Dobrev, 2005a). Тази дефиниция получи голямо разпространение, защото в момента в *Google* на въпроса *Definition of Artificial Intelligence* първият резултат, който се появява, е тази статия.

Проблем на тази дефиниция е, че тя е неформална. За да се формализира дефиницията, беше въведен коефициент на интелигентност (*IQ*). На всяка програма се съпоставя едно число, което е нейното *IQ*, и за ИИ се приемат тези програми, чието *IQ* е достатъчно високо. Този подход е в основата на статията Dobrev (2019b). Тази статия не е част от дисертацията, защото има някои недостатъци. Например там се предполага, че дължината на живота и сложността на света са ограничени (т.е. че са фиксирани). Друг проблем е, че се оказва, че тази идея вече е реализирана в публикациите Hernández-Orallo et al., 1998 и Hutter, 2000.

По-късно беше приет друг подход (Dobrev, 2022a). Този друг подход е добавен като част от тази дисертация. Предимство на новия подход е, че дължината на живота и сложността на света не са ограничени. Друго предимство на новия подход е, че се разглеждат различни езици за описание на света, докато при първия подход се разглеждаше само описание чрез изчислими функции.

Вторият въпрос. За да се създаде ИИ, трябва да се направи програма, която може да „разбере“ света и на базата на това, което е разбрала, да планира бъдещото си поведение. Да „разберем“ света означава да го опишем чрез някакъв език за описание на светове. Затова създаването на подходящ език за описание на света е съществена част от създаването на ИИ.

Втората част на дисертацията е посветена на описанието на един такъв език, който претендира да е подходящият език за описание на светове (Dobrev, 2022b и 2023). Важна част от този език са алгоритмите. Пример за алгоритъм е „Чакам, докато дойде“. Статията Dobrev (2023) включва дефиниция на алгоритъм, която обобщава стандартната дефиниция на изчислима функция. Според новата дефиниция алгоритъмът е последователност от действия, която може да бъде извършена в произволен свят. В частния случай, когато светът се състои от безкрайна лента и глава, която чете от лентата и пише върху нея, тогава алгоритъмът е машина на Тюринг.

Третият и най-важен въпрос е свързан с последствията от създаването на ИИ. Този въпрос много малко хора си го задават. Хората са като любопитни деца, които обичат да си играят с кибрит, без да мислят, че може да предизвикат пожар. Макар и малко, все пак има научни статии, които обсъждат бъдещето, което ще дойде след създаването на ИИ. Пример за такава статия е Alfonso et al. (2021). Друг пример е Ivanova et al. (2020), където се обсъжда влиянието на ИИ върху пазара на труда и как трябва да се промени образованието в тази връзка.

Основният въпрос е: „Трябва ли да създаваме ИИ и можем ли да не го създаваме?“. Отговорът е, че не можем да не го създаваме, защото ако ние не го създадем, ще го създаде някой друг. По-добре е да помислим и да се подготвим за последствията и все пак да внимаваме да не изтървем духа от бутилката.

Отговорът на третия въпрос ще ни е нужен чак когато вече сме направили ИИ. Това не значи, че трябва да чакаме появата на ИИ и чак тогава да си зададем въпроса „И сега какво ще правим?“. Ако чакаме до момента, в който този въпрос стане наложителен, ще допуснем огромна грешка. Когато ИИ се появи, вече ще е много късно да се питаме: „А сега накъде?“. Този въпрос трябва да сме си задали много преди реалната поява на тази машина (т.е. на тази програма, защото ИИ не е машина, а е програма, както ще видите по-долу).

Приноси на дисертацията:

1. Предлага се неформална дефиниция на ИИ и тази неформална дефиниция днес е широко разпространена (в момента това е първият резултат, който *Google* връща при въпроса *Definition of Artificial Intelligence*).

2. Дава се строга математическа дефиниция на ИИ. Предложената строга дефиниция не е изцяло наша заслуга, защото тя е едно подобрение на дефиницията на ИИ, която първоначално е създадена от Hernández-Orallo през 1998 (Hernández-Orallo et al., 1998) и която съществено е подобрена от Marcus Hutter през 2000 (Hutter, 2000).

3. Въвежда се език за описание на светове, при който описанието може да се търси автоматично без помощта на човек. Има и други езици за описание на светове, които са създадени преди нашия език, но предимство на предложението от нас език е, че при него описанието на света може да се търси автоматично, докато при другите подходи се предполага, че има човек, който е разбрал света и който ще го опише на съответния език.

Структура на дисертацията:

Тази дисертация се състои от три части, като всяка от тези части е посветена на един от трите основни въпроса, свързани с ИИ.

Първата част отговаря на въпроса „Какво е ИИ?“. Този част се състои от две глави, озаглавени съответно „неформална дефиниция“ и „формална дефиниция“. По същество тези две глави са статиите Dobrev (2000) и Dobrev (2022a).

Втората част разглежда въпроса „Как да направим ИИ?“. Този част по същество се състои от статиите Dobrev (2022b, 2023).

Третата част се състои от две глави. Първата е статията Dobrev (2019c), а втората глава предстои да бъде допълнена и издадена като отделна статия.

1 Какво е изкуствен интелект?

1.1 Неформална дефиниция

В тази дисертация ще си зададем въпросите: „Трябва ли ни да знаем какво е ИИ?“ и „Какво е интелект?“. След това ще дадем една дефиниция за изкуствен интелект. Накрая от тази дефиниция ще получим алгоритъм, който след краен брой стъпки ще открие ИИ.

1.1.1 ИИ – Какво е това?

Трябва ли ни да знаем какво е ИИ? На този въпрос ще отговорим просто: *Да, ако искаме да го открием, то определено ще е по-лесно да го намерим, ако знаем какво търсим.* В противен случай ще се окажем в положението на алхимиците, които са търсели философския камък, но почти не са имали представа какво е това.

Най-известната дефиниция на ИИ е така нареченият Тюрингов тест. Тюринг е английски математик, известен както с машините на Тюринг, така и с разбиването на немските кодове по време на Втората световна война.

Тюринговият тест е доста прост. Поставяме нещо зад една завеса и то разговаря с нас. Ако не можем да го различим от човек, то това е ИИ. Тази дефиниция е по-стара от петдесет години и затова ще се опитаме да направим нова, по-съвременна.

Дефиницията на Тюринг предполага, че *интелект* е човек с натрупаните през годините знания. А *интелект* ли е бебето, което току-що се е появило на бял свят? Нашият отговор ще е „да“. Тоест нашата дефиниция за интелект ще е това, което не знае нищо, но може да се научи. Тук се различаваме от повечето хора, които като чуят *интелект*, си представят професор от университета.

Преди да дадем формална дефиниция на ИИ, ще направим уговорката, че приемаме тезиса на Чърч, който гласи, че всяко изчислително устройство може да се моделира с програма. Т.е. ние ще търсим ИИ в множеството на програмите. Ще предположим, че ИИ е стъпково устройство, което живее в някакъв свят, на всяка стъпка получава информация (от света) и въздейства (на света) чрез информацията, която извежда. Ще допуснем още, че информацията, която получава и предава на всяка стъпка, е крайно много. Например получава n бита и предава m бита.

След тези уговорки можем да изкажем неформално нашата дефиниция. **ИИ ще наричаме такава програма, която в произволен свят би се справила не по-зле от човек.**

Следващата задача ще е да формализираме тази дефиниция, за да можем да я използваме и с нея да търсим ИИ. Първо, какво за нас ще е свят? Това ще са две функции **World(s, d)** и **View(s)**. Първата ще взима като аргументи състоянието на света и въздействието, което оказва на света нашето устройство. Като резултат тази функция ще връща новото състояние на света (което той ще има на следващата стъпка). Втората функция ще ни казва какво вижда нашето устройство. Аргумент на тази функция ще е състоянието на света, а получената стойност ще е информацията, която ще получава устройството (на дадена стъпка). Трябва да добавим и един елемент s_0 , това ще е състоянието на света, когато нашето устройство се е родило. По време на живота му светът ще премине през състоянията s_0, s_1, s_2, \dots . Устройството ще въздейства на света с информацията, която извежда на всяка стъпка d_0, d_1, d_2, \dots . Също така ИИ ще получава информация от света v_0, v_1, v_2, \dots . Ясно е, че $s_{i+1} = \text{World}(s_i, d_i)$ и че $v_i = \text{View}(s_i)$.



Дотук имаме всичко. Имаме свят и устройство, което живее в него. Липсва само едно, смисъла на живота. Какво е животът без болка и радост, ще кажат философите. Затова ще въведем смисъл на живота. Това ще е оценка, която ни казва дали една редица v_0, v_1, v_2, \dots е по-добра от друга.

За повечето хора животът е протекъл по-добре, ако са видели повече швейцарски курорти и по-малко каменовъглени мини. Горе-долу и ние така ще дефинираме смисъла на живота. Ще отделим от v_i два бита, които ще наречем „победа“ и „загуба“, и смисълът ще е да се получат повече победи и по-малко загуби.

Остана последната стъпка: да се даде алгоритъм, който ще открие ИИ. Идеята ще е да пуснем всички програми върху всички светове и да отделим тези, които се справят най-добре. Това не звучи като алгоритъм, все едно да проведем безкраен изпит с безброй много кандидати. Това, че кандидатите са безброй много, не е проблем. На нас не ни трябват всички, а само някои от издържалите изпита. Обаче това, че изпитът е безкраен и никога няма да свърши за нито един кандидат, е проблем.



За да направим изпита краен, ще ограничим световите до краен брой. Но дори само за един свят изпитът би бил безкраен, затова ще добавим изисквания за ефективност. Ще кажем за всеки от световите колко време (такта) даваме на устройството за обучение и какъв успех трябва да постигне, след като се е обучило (например в следващите сто такта съотношението на победи към загуби да е поне 9 към 1). Още ще ограничим времето и паметта, които устройството ще може да използва на една стъпка. Тези изисквания не трябва да са твърде крути, защото нашият ИИ няма да ги удовлетвори и ще пропадне на изпита.

Ще предполагаме още, че в световите, които сме подбрали за изпита, няма фатални грешки. Ако имаше, то търсеният ИИ би могъл да направи такава грешка, докато се обучава, и да пропадне на изпита. Разбира се, ако този ИИ живее в този свят много пъти, то средно ще постигне една добра оценка, но ние искаме да го пускаме само по веднъж на свят.

Реалният свят не отговаря на това изискване, защото може да си Айнщайн, но да бъдеш изяден от някоя мечка, още преди да си осъзнал теорията на относителността. Т.е. да допуснеш фатална грешка, преди да си се обучил. Пример за свят без фатални грешки е, ако нашето устройство играе шах срещу някакъв противник. След края на всяка партия

започва следваща. В този свят ИИ може да загуби много партии, но това няма да се отрази на следващите.

След като направихме изпита краен, то сега нашият алгоритъм може да започне да генерира програмите една по една, да подлага всяка на изпита и да извежда тези, които са го издържали. Ще считаме, че нашият алгоритъм изрежда програмите по сложност (т.е. по дължина). Т.е. първо ще изведе най-простата (късата) програма от тези, които издържат изпита. Дали тази програма ще е ИИ, или нашият ИИ ще се генерира по-късно? Тук трябва да отбележим, че не всички програми, издържали изпита, са ИИ. Например, ако напишем програма специално за световите, върху които тестваме, то тя ще мине, но няма да е ИИ. Този проблем го имаме и с кандидатстудентските изпити. На тях минават много хора, които са зазубрили всички типове задачи, но това не са интелекти, а зубрачи.

Ще считаме, че световите, които сме включили в изпита, са достатъчно много и достатъчно разнообразни (по-големият брой задачи не утежнява изпита за преподавателя, защото повечето кандидати ще пропаднат още в началото). При това положение ще се отсеят почти всички програми, които не са ИИ. Следователно първата (най-простата), която ще се изведе, ще е ИИ, а тази, която е написана само за световите от изпита, ще е по-сложна и ще се изведе по-нататък.

Значи вече разполагаме с алгоритъм за откриването на ИИ! Значи ли това, че всеки сносен програмист може да напише програма по него, да я пусне, да почака малко и тя ще му изведе търсения ИИ. Отговорът е „Да, така е, но времето, което ще се наложи да почакате, ще е доста (да кажем сто хиляди години)“. Причината за това се крие в явлението, наречено „комбинаторен взрив“. Не е трудно да се напише програма, която се очаква да спре след смъртта на вселената (например прибавяйте единица към 10-байтов брояч, докато не се препълни).

Горното означава, че описаният алгоритъм е напълно безполезен, но не така стои въпросът с дефиницията на ИИ. Сега, след като знаем какво е ИИ, можем да се опитаме да го построим директно и да използваме алгоритъма, за да се убедим, че това наистина е ИИ.

След като нашето устройство е издържало изпита във всички тестови светове, можем да го пуснем и в нашия (реалния) свят. Разбира се, то няма да е готово веднага да премине през теста на Тюринг, защото в най-добрия случай зад завесата ще се чуе само едно гукане. Нашето устройство ще се нуждае първо от възпитателки и гувернантки, които да го научат на добри обноски. Учителите ще трябва да го поощряват, като подават единица на шината му – победа и да го наказват чрез шината загуба. Така нашият ИИ ще се труди прилежно, старайки се да получи максимално много поощрения и минимално наказания. Може би тогава няма да програмираме компютрите, а ще ги възпитаваме и обучаваме. И може би един ден, след като ги възпитаваме и обучим, ще станем излишни.

1.2 Формална дефиниция

1.2.1 Дефиниция на ИИ и програма, която удовлетворява тази дефиниция

Ще разгледаме всички възможни стратегии на агента и ще покажем, че една от тях е най-добрата. Тази стратегия не е изчислима, но има близки до нея изчислими стратегии. Ще дефинираме ИИ като изчислима стратегия, която е достатъчно близо до най-добрата. За да определим най-добрата стратегия на агента, ни е нужен език за описание на света. Чрез този език ще направим и програма, удовлетворяваща дефиницията на ИИ. Програмата първо ще разбере света, като го опише чрез избрания език, после на базата на това описание ще предскаже бъдещето и ще избере възможно най-добрия ход. Тази

програма е изключително неефективна и на практика неизползваема, но тя може да бъде подобрена чрез усъвършенстване на езика за описание на света и чрез подобряване на алгоритъма за предсказване на бъдещето. По този начин може да се получи ефективна програма, удовлетворяваща дефиницията на ИИ.

1.2.2 Въведение

Преди време разговарях с колега, който ми каза следното: „Може би един ден ние ще създадем ИИ, но това ще бъде една изключително неефективна програма и за нея ще ни е нужен безкрайно бърз компютър“. Моят отговор беше: „Ти ми дай тази неефективна програма, която е ИИ, а аз ще я подобра и ще направя от нея истински ИИ, който може да работи на реален компютър“.

Днес, в тази дисертация, аз давам това, което навремето поисках от моя колега. Давам неефективна програма, удовлетворяваща дефиницията на ИИ, и дори давам идеи и насоки как тази неефективна програма може да се подобри и да стане реална програма, работеща в реално време. Надявам се някой от читателите на тази дисертация да направи това и да създаде търсения от нас ИИ.

Доколко неефективна е тук описаната програма? На теория има само два вида програми – завършващи и зациклящи, но на практика някои от завършващите програми са толкова неефективни, че можем да мислим за тях като за зациклящи. Тази програма е такава и поради това е неизползваема (освен ако компютърът е безкрайно бърз или светът е съвсем елементарен).

Трикове. В тази дисертация ще използваме математически трикове, които няма да харесат на инженерите. Математиците често доказват съществуването на неконструктивни обекти. Това са добре дефинирани обекти, които съществуват, но не могат да бъдат посочени. В тази дисертация ще дефинираме „най-добрата стратегия“, която е неизчислима и затова е неконструктивна. Алгоритмите са описанието на изчислимите стратегии, но тази стратегия си няма алгоритъм. За инженерите тази стратегия е безсмислена, защото те работят само с конструктивни обекти.

Ще въведем още изчислима стратегия, която е достатъчно близо до най-добрата. Това е конструктивен обект, но той също няма да се хареса на инженерите, защото ще се изчислява от програма, която изисква безкрайно бърз компютър. Тоест, от гледна точка на инженера, тази програма няма да е изчислима, защото реално изчисление имаме, когато то се случва за реално време. Тоест тук ние ще дефинираме ИИ като програма, чиято ефективност е без значение, докато в реалния живот ние се интересуваме само от ефективни програми, които могат да се използват реално.

Друг трик е, че ще използваме безкрайни обекти, които са любими на математиците, но са недолюбвани от инженерите. Защо математиците предпочитат безкрайните обекти, макар в реалния живот такива обекти да не се срещат? Защото нещата стават по-интересни, когато имаме безкрайност. Например всички крайни функции са изчислими. За да имаме неизчислими функции, ни трябва безкрайност. Всички крайни функции могат да бъдат описани, а безкрайните са континуум много и само изброима част от тях могат да бъдат описани. Когато имаме безкрайност, нещата стават не само по-интересни, но и по-прости. Това е причината, поради която разглеждаме компютъра като машина на Тюринг (като безкрайна функция), макар че той на практика е краен автомат. Много по-просто е да си мислим, че паметта на компютъра е неограничена и че той изчислява безкрайни функции. Аналогично, за ИИ ще е много по-просто да си мислим, че времето му е неограничено.

Каква е дефиницията на ИИ? Ще дефинираме ИИ като стратегия. Ако агентът следва тази стратегия, то той ще се справи достатъчно добре. Това важи за произволен свят, в който няма фатални грешки. Ако в света фатална грешка е възможна, тогава агентът може и да не се справи добре в този свят, но средното му представяне върху всички възможни светове пак ще е достатъчно добро.

Кои ще са възможните светове? Стратегиите на света са континуум много. Ако нямаме никакво очакване за това какъв е светът, то няма как да имаме очакване за това какъв е очакваният успех на агента. Ще предположим, че светът може да се опише и че неговото описание е възможно най-просто (това предположение е известно под името „бръснач на Окам“). Тоест избираме един език за описание на светове и се ограничаваме до световите, описани чрез този език. Световите, чието описание е по-просто (по-кратко), ще бъдат предпочитани (ще имат по-голяма тежест).

В тази дисертация ще разгледаме няколко езика за описание на света. Първият език ще описва детерминирани светове. В този език светът ще се описва чрез изчислима функция, която от състоянието на света и действието на агента изчислява новото състояние на света и следващото наблюдение. В този случай, ако знаем началното състояние на света и действията на агента, получаваме живота на агента в този свят.

Вторият език ще описва недетерминирани светове. Отново имаме изчислима функция. Този път изчислимата функция има още един аргумент и това е случайността. Тук, за да получим живота на агента в този свят, ни трябва да знаем още каква е била случайността.

Ще дефинираме ИИ чрез тези два езика и ще направим предположението, че тези две дефиниции съвпадат. Ще направим дори предположението, че дефиницията на ИИ не зависи от това кой език за описание на света сме избрали и че всички езици дават една и съща дефиниция на ИИ.

На базата на тези два езика ще направим две програми, които удовлетворяват дефиницията на ИИ. Тези две програми изчисляват приблизително една и съща стратегия, но тяхната ефективност е съвсем различна. Тоест езикът за описание на света не влияе върху дефиницията на ИИ, но силно влияе върху ефективността на получения чрез този език ИИ.

Приноси.

Тази дисертация подобрява дефиницията на ИИ, която първоначално е създадена от Hernández-Orallo през 1998 (Hernández-Orallo et al., 1998) и съществено е подобрена от Marcus Hutter през 2000 (Hutter, 2000). Подобренията са две.

1. Дефиниция на ИИ, която не зависи от дължината на живота. В (Orallo 1998 and Hutter 2000) е дадена дефиниция на ИИ, но там се предполага, че дължината на живота е ограничена с някаква константа, която се явява параметър на дефиницията.

2. Дефиниция на ИИ, която не зависи от езика за описание на света. В Hutter (2000) езикът е фиксиран. Тоест в Hutter (2000) се предполага, че има само един възможен начин, по който може да се опише светът.

1.2.3 Литературен обзор

1.2.3.1 Генерален интелект

Първо ще отбележим, че в тази дисертация, когато говорим за „изкуствен интелект“, имаме предвид „генерален изкуствен интелект“. В литературата се разглеждат два вида ИИ, които са наречени тесен и генерален (понякога ги наричат слаб и силен). Според мен по-правилно е тези два вида ИИ да бъдат наречени фалшив и истински ИИ.

Нека вземем като пример диамантите. И при интелекта, и при диамантите имаме деление на естествени и изкуствени. Изкуствените диаманти се делят на два вида – истински (състоящи се от въглерод) и фалшиви (направени от стъкло). Днес, когато говорим за изкуствен диамант, имаме предвид такъв, който е направен от въглерод. Нека си представим, че живеем в XIX век и все още никой не може да направи изкуствен диамант от въглерод. През XIX век, когато хората са говорили за изкуствен диамант, са имали предвид диамант от стъкло. Това е нещо, което прилича на диамант, но не е диамант. Днес наричаме диамантите от стъкло фалшиви диаманти.

Истинският изкуствен диамант по нищо не отстъпва на естествения. Като твърдост и прозрачност тези два диаманта са еднакви. Все пак имаме разлика в цената, защото изкуственият е много по-евтин от естествения, но той може да го превъзхожда по големина и по чистота.

Същото е с изкуствения интелект. Ако вземем истинския изкуствен интелект, той по нищо не отстъпва на естествения, но може да го превъзхожда в бързина, памет и „интелигентност“. Естествено, цената на изкуствения интелект ще е много по-ниска от тази на естествения. Днес, през XXI век, естественият интелект дори е безценен, защото не се продава.

Що се отнася до слабия или тесния изкуствен интелект, той прилича на интелект, но не е. Когато вече имаме истински изкуствен интелект, тези програми ще се наричат „фалшив изкуствен интелект“ или „програми, имитиращи интелигентност“.

Днес в повечето статии, когато се говори за ИИ, се има предвид тесен или фалшив ИИ. В тази дисертация, когато говорим за ИИ, имаме предвид генерален или истински ИИ.

1.2.3.2 Интуитивна дефиниция

Нека да направим литературен обзор и да разгледаме статиите, които са посветени на дефиницията на ИИ. Тази дефиниция е много важна и това е основният въпрос в ИИ. Въпреки това, тези статии са много малко, защото повечето изследователи въобще не си задават въпроса „Какво е ИИ?“ – малцина са тези, които си го задават. Причината е, че нашите колеги не вярват в ИИ. Ако не вярваш в призраци, не си задаваш въпроса „Какво е призрак?“. Наскоро присъствах на лекцията на един от водещите специалисти в областта на ИИ (Solar-Lezama, 2023). Той каза: „Колкото и умен да е ИИ, винаги ще се намери някой човек, който да е по-умен от него“. Явно този наш колега не вярва в ИИ и не може да си представи, че един ден ИИ ще е по-умен от всеки човек.

Статиите, посветени на дефиницията на ИИ, са малко, но все пак има такива. Много добър обзор на тези статии е направен в Wang 2019 и в статиите на Hernández-Orallo (2012, 2014a, 2014b, 2014c, 2017). Тук ще направим един по-кратък обзор, като ще се опитаме да кажем неща, които не са казани в споменатите обзорни статии.

Първата интуитивна (неформална) дефиниция на ИИ е направена от Алан Тюринг (Turing, 1950) и е известна под името „тестът на Тюринг“. Тази дефиниция е перфектна в своята простота. Все пак в нея има един съществен проблем. Тестът на Тюринг дефинира

обучен интелект (тоест интелект плюс образование). Бихме искали да имаме дефиниция на необучен интелект (тоест интелектът без образованието). Първата дефиниция на чист необучен интелект е дадена от Pei Wang през 1995 г. (Wang, 1995). Нейното съдържание е следното:

*Intelligence is the capacity of an information-processing system to adapt to its environment while operating with insufficient knowledge and resources.*²

По-късно, през 2000 г., дефиницията на Pei Wang е подобрена. Това подобрение е публикувано в Dobrev (2000). Днес това е първият резултат, който Google дава за дефиниция на ИИ. При заявката *Definition of Artificial Intelligence* първият резултат е статията Dobrev (2005a), която е подобрена версия на Dobrev (2000). Ето как изглежда подобреният вариант на дефиницията на Pei Wang:

*AI will be such a program which in an arbitrary world will cope not worse than a human.*³

В какво се състои подобрението? Първо, Pei Wang дефинира интелект, а подобрения вариант дефинира изкуствен интелект. Това подобрение не е съществено, защото истинският въпрос е „Какво е интелект?“. Това, че ИИ е програма, следва директно от тезиса на Чърч (Church, 1941), който казва, че всяка информационна система може да се емулира с компютърна програма.

Същественото подобрение на дефиницията на Pei Wang е, че там се иска интелектът да може да се справи в един конкретен свят (в своята среда), докато в подобрения вариант се иска ИИ да може да се справи добре във всеки свят. Защо това подобрение е съществено? В крайна сметка, за нас е важно ИИ да се справи добре в своята среда, защото това е важната среда, която ни интересува. ИИ обаче не трябва да зависи от средата, защото ние искаме да можем да го поставяме в различни среди (светове) и искаме ИИ да може да се справи добре навсякъде. Да кажем, че за нас е важен реалният свят, но този свят не е единствен. Има голямо значение къде и кога си се родил. Ако се променят някои от тези параметри, светът ни може да изглежда по съвсем различен начин. Очевидно Pei Wang е съзнавал, че светът не е единствен, и затова е добавил към дефиницията *while operating with insufficient knowledge and resources*. Тоест Pei Wang иска ИИ да може да се справи и когато е трудно, като идеята е, че щом се справя, когато е трудно, ще се справи и когато е лесно. Разбира се, когато си необразован и беден е трудно. Много по-лесно би било, ако разполагаш със знания и ресурси.

Още едно подобрение на дефиницията на Pei Wang е, че там не се казва колко добре трябва да се справи ИИ. Там се предполага, че или се справя, или не се справя, но знаем, че някои се справят по-добре, а други – по-лошо. Тоест важно е колко добре се справя ИИ и това е неговото ниво на интелигентност. В подобрения вариант на дефиницията се казва, че ще се справи не по-зле от човек. Сравнението с човек прави дефиницията неформална, но то е важно, защото трябва да отбележим кое ниво на интелигентност е достатъчно, за да приемем, че дадена програма покрива изискванията за ИИ.

² Интелигентността е способността на една информационна система да се адаптира към своята обкръжаваща среда, дори когато оперира с недостатъчно знания и ресурси.

³ ИИ ще бъде такава програма, която в произволен свят би се справила не по-зле от човек.

1.2.3.3 Една дискусия

Много сериозна дискусия около дефиницията на Pei Wang е направена в *Journal of Artificial General Intelligence, Volume 11 (2020): Issue 2 (February 2020), Special Issue “On Defining Artificial Intelligence” – Commentaries and Author’s Response*.

В тази дискусия Shane Legg отбелязва, че дефиницията на ИИ не е задължителна (Legg, 2020). Той казва, че икономистите нямат точна дефиниция на понятието „икономика“, но това не им пречи да развиват своята наука. Не можем да се съгласим с това твърдение. Икономистите изучават нещо съществуващо, а ние се опитваме да създадем нещо, което още не съществува. Затова ние трябва да си отговорим на въпроса „Какво е ИИ?“, защото в противен случай никога няма да разберем дали сме намерили това, което търсим.

Richard Sutton в (Sutton, 2020) обръща внимание на дефиницията на John McCarthy:

Intelligence is the computational part of the ability to achieve goals in the world.

Може да се каже, че дефиницията на McCarthy повтаря дефиницията на Wang, но с други думи. Може да приемем, че „*adapt to its environment*“ е синоним на „*achieve goals in the world*“. При всички случаи трябва да кажем кога една програма се справя по-добре от друга. Не е важно дали това справяне ще го наречем адаптиране или постигане на цели.

Все пак в разсъжденията на Sutton има нещо, с което по никакъв начин не можем да се съгласим. Sutton слага знак за на равенство между уменията да се реши една определена задача и уменията да се реши произволна задача. Примерите за конкретни задачи, които той дава са thermostat и chess-playing program. Програмите, които решават конкретни задачи не са интелигентни. Интелигентността е способността да се реши произволна задача. Същият проблем срещаме и при John Laird (Laird, 2020). Той твърди, че системите Chinook, Deep Blue, и Watson са интелигентни, а те не са, защото това са програми решаващи една конкретна задача, а не всяка задача.

Roger Schank казва, че компютрите не могат да бъдат интелигентни (Schank, 2020). Напълно сме съгласни с него. ИИ е програма. Дори и най-мощния и бърз компютър ще е глупав, ако го пуснем да изпълнява глупава програма. Също така Schank казва: „*AI is now just about counting.*“ Действително днес в нашата област има известно залитане по свръхмощните изчисления, но тези изчисления вече изглеждат интелигентни и им е нужно още съвсем малко, за да станат действително интелигентни.

François Chollet казва, че дефиницията трябва да измерва „degree of intelligence“ (Chollet, 2020). Съгласни сме с това. По-горе казахме, че трябва да има различни нива на интелигентност.

Joscha Bach отбелязва, че в дефиницията на Wang ИИ зависи от средата, в която е поставен (Bach, 2020). Действително и ние отбелязахме, че трябва да се справи във всяка среда.

Tomáš Mikolov и Roman Yampolskiy правят забележката, че ние разглеждаме ИИ като отделно същество, а не като нещо създадено от човека, което трябва да служи на човека (Mikolov, 2020) и (Yampolskiy, 2020). От една страна ще се съгласим с тях, но от друга ще кажем, че не трябва да разглеждаме всичко като производно на човека. Чували сме природозащитници да казват „Ние избиваме много животински видове, а в тялото на някое от тези същества може да се съдържа безценно лекарство, което да излекува много

хора“. Ще кажем на тези природозащитници, че живите същества имат право на собствен живот и смисъла на тяхното съществуване не е да удовлетворяват нашите нужди. Същото се отнася и до ИИ. Това е понятие, което съществува независимо от човека. Дали ИИ ще ни бъде полезен и ще работи за нас или ние ще работим за него, това е нещо, което зависи от това как ще го направим и дали няма да го изпуснем от нашия контрол.

Alan Winfield ни обръща внимание, че има различни видове интелигентност (Winfield, 2020). Това е така. Наблюдаваме при хората, че различните хора се справят различно с различните задачи. Например има много добри математици, които са доста неумели в общуването в обществото. Winfield говори за социална интелигентност. За тази интелигентност е много важно в модела на света да се включат повече агенти. Тоест преминаването от едноагентен към многоагентен модел на света е съществено за социалната интелигентност. Този въпрос е разгледан в настоящата дисертация, където ще разглеждаме език за описание на света с много агенти. Peter Stone също казва, че има различни видове интелигентност (Stone, 2020). Той дори настоява за различните типове интелигентност да има различни дефиниции. Тук не можем да се съгласим с него. Например имаме различни видове автомобили. Имаме спортни и товарни автомобили, но това не пречи да има обща дефиниция за автомобил.

John Fox предлага да стесним множеството на възможните светове и да се съсредоточим в областта на медицината (Fox, 2020). От една страна той е прав, че тази област е достатъчно сложна и ако създадем програма, която се справя в тази област, то тази програма вероятно би се справила в произволна област. От друга страна областта на медицината е толкова сложна, че съсредоточаването в тази област няма да облекчи задачата, а по-скоро ще я затрудни.

Raúl Rojas ни казва, че дефиницията на ИИ е като хоризонта и че когато се доближаваме до нея, тя се отдалечава (Rojas, 2020). Много неща в миналото сме приемали за ИИ, но днес вече не мислим така, защото това са задачи, които компютърът вече решава и при това ги решава по-добре от човека. Действително, това е така при дефиницията на тесния ИИ. Що се отнася до дефиницията на генералния ИИ, то тя не бяга и не се мести. Raúl Rojas ни казва, че естественият и изкуственият интелект няма да се слее (converge). Напълно сме съгласни с него. Изкуственият интелект ще догони естествения в малкото области, където все още не може да го достигне. Резултатът ще е интелект, който значително превъзхожда естествения във всички области. Тоест няма да се получи доближаване а силно разминаване.

Gianluca Baldassarre и Giovanni Granato предлагат да копираме човешкия мозък (Baldassarre, 2020). Действително биониката е основен метод в инженерните дисциплини, но този метод не трябва да се надценява. Например авиоинженерите изучават птиците, но съвременните самолети не приличат на птици и летят по-бързо и по-високо от тях. Може да се използват някои общи принципи, но никой съвременен самолет не маха с крила.

Aaron Sloman повдига няколко интересни философски въпроса (Sloman, 2020). Например той задава въпроса дали ИИ ще има чувства. Действително интелигентността на човека се основава на чувства. Мотивацията на човека също минава през чувства. Човекът няма ясно дефинирана цел на своето съществуване. Можем да прием, че целта на човека е оцеляване и възпроизводство, но тези цели не са вградени в естествения интелект и човекът не осъзнава, че това е целта му. Вместо вградена цел човекът има инстинкти, които водят към чувства, които индиректно го водят до желание за оцеляване и възпроизводство. Например страхът от височина е инстинкт, който води до страх, който помага за оцеляването. Подобно е и със сексуалното желание и любовта.

Когато конструираме ИИ дали е добре да използваме чувства, за да дефинираме неговите цели? Когато ИИ играе шах, той се стреми към победа. Можем да кажем, че победата е удоволствие за него. Дали да добавим още страх, завист, любов и други чувства. Истината е, че когато един човек е много емоционален, с него трудно се живее. Може би е разумно, когато конструираме ИИ, да не го правим прекалено емоционален.

Peter Lindes ни обръща внимание на това, че термина ИИ се използва в два смисъла (Lindes, 2020). Първият това е съществото ИИ, а вторият това е науката ИИ. Тук ние говорим само за първия смисъл на термина.

Peter Lindes повдига още един интересен въпрос. Той добавя към ИИ още едно препятствие. Искаме ИИ да може да се справи дори когато е необразован и беден, но Lindes добавя към това да имаме още ограничение в паметта и компютърната мощ. Изглежда сякаш добавяме изискването ИИ да е глупав, което вече е прекалено. Всъщност изискването за ограничение на паметта и компютърната мощ не означава ИИ да е глупав. ИИ е програма и тази програма може да бъде изпълнена на най-различни компютърни конфигурации. Може да бъде изпълнена на конфигурация с повече памет и по-голямо бързодействие. По-умна ще е тази програма, която би тръгнала и на по-прост компютър. Тоест добавянето на това допълнително изискване въобще не е лишено от логика.

Istvan Berkeley ни обръща внимание, че днес фразата ИИ се използва за маркетингови цели и всеки търговец ни убеждава, че това което продава има в себе си вграден ИИ (Berkeley, 2020). Според Berkeley има много програми, които са ИИ, но не отговарят на дефиницията на Wang. Всъщност тези програми действително не са ИИ и не трябва да се наричат ИИ, нищо че търговците така ги наричат.

Marek Rosa отбелязва, че не можем да пуснем ИИ да живее в произволен свят, защото този свят ще е прекалено сложен и той няма как да се справи в него (Rosa, 2020). Задачите, които ще решава ИИ трябва да идват в подходящата последователност и първо да дойдат по-леките задачи и чак когато простите задачи са решени да дойдат и по-трудните задачи. Човекът живее в свят с учител, който му поднася задачите в правилната последователност. Допълнително учителят помага като показва как се решават задачите. В дефиницията на Wang нищо не се казва за учителя, но се предполага, че това може да е една допълнителна екстра, която може да съществува и ИИ трябва да е готов да се възползва от тази допълнителна екстра, когато я има.

Matthew Crosby и Henry Shevlin обръщат внимание на това, че ние не живеем сами, а в общество (Crosby, 2020). Те отбелязват, че гениалният композитор ще умре от глад, ако не са другите агенти, за да го хранят. Действително, когато разглеждаме произволен свят, приемаме, че светът е многоагентен (в общия случай). В настоящата дисертация ние разглеждаме език, който описва многоагентни светове и в тези светове основна способност на ИИ е да може да общува и да се разбере с останалите агенти.

Kristinn Thórisson казва, че интелигентността се основава на измислянето на невидимите неща (Thórisson, 2020). В настоящата дисертация ние стъпваме на същата идея. Търсим език за описание на света. Това, което описва този език, е скритото състояние на света. Тоест да опишем скритото състояние означава да измислим света или да си го представим.

William Raparort задава въпроса дали интелигентността е изчислима (Raparort, 2020). Всъщност това е въпросът, който разделя вярващите в съществуването на ИИ от неверниците. Ние сме от вярващите и затова за нас интелигентността е изчислима.

Това са нашите кратки забележки към авторите, които са взели участие в дискусията. Трябва да поздравим организаторите на тази дискусия, защото са събрали много изтъкнати учени в областта, които са дали много смислени и интересни мнения по въпроса за това коя трябва да е дефиницията на ИИ.

Подробен отговор на въпросите повдигнати в дискусията е даден в Wang (2020).

1.2.3.4 Естествен интелект

Когато говорим за естествен интелект, имаме предвид интелекта на човека. Разбира се, животните също имат интелект и по някои параметри той надминава човешкия. Например дългосрочната памет на слоновете е по-добра от тази на хората. Експерименти показват, че краткосрочната визуална памет на маймуните е значително по-добра от тази на хората.

Човешкият интелект се отличава с мислене. Има два вида мислене – логическо мислене, което е многостъпково, и асоциативно мислене (разпознаване), което е едностъпково. В областта на разпознаването компютрите вече са изпреварили хората. С помощта на невронните мрежи компютрите вече разпознават лица и гласове много по-добре от нас, хората. Логическото мислене е последното, в което ние, хората, водим пред компютрите.

Способни ли са животните на логическо (многостъпково) мислене? Още моят дядо, който е бил биолог, е провеждал експеримент, в който е учил кокошките да броят (Dobrev, 1993). Тоест животните са способни на многостъпково мислене и това отдавна е известно.

1.2.3.5 Логическо мислене

Какво е нужно, за да започнат компютрите да мислят многостъпково (логически)? Нужно е скрито състояние. Тоест трябва да се премине от *full observability* към *partial observability*. Когато мислим многостъпково, това, което се променя на всяка стъпка, е вътрешното състояние на света. Бихме ли могли вместо това да променяме *наблюдението*? По принцип би могло, но при *full observability* виждаме твърде много и би трябвало да отделим една част от наблюдението и да я променяме в процеса на логическото мислене. По-естествено е отделената част от наблюдението да бъде представена като скрито състояние на света.

За логическото мислене е нужно „разбиране“. Трябва да разберем „какво става?“. Това означава да опишем скритото състояние на света. За целта ни е нужен език за описание на светове. Можем да си мислим за скритите състояния на света като за някакво изброимо множество, като числа или като думи над някаква азбука. Смисълът на тези думи ще се даде от езика за описание на светове.

Днешните чатботове като *ChatGPT* (OpenAI, 2022) дават поразителни резултати. Въпреки всичко, когато разговаряме с тях, имаме чувството, че им липсва „разбиране“. Оставаме с неприятното усещане, че разговаряме с папагал. Разбира се, разговорът с *ChatGPT* е несравнимо по-пълноценен от разговора с папагал, но има още какво да се желае.

Освен това в тези чатботове има малко измама. Например *ChatGPT* според Yahav (2023) се състои от две части – невронна мрежа и алгоритми, написани от програмисти. Невронната мрежа не е способна на многостъпково мислене, но *ChatGPT* ни заблуждава, че мисли многостъпково благодарение на добавените алгоритми, написани от програмисти. Например за събирането на две числа е нужно такова многостъпково разсъждение и събирането се извършва от един от добавените алгоритми. Защо това е

измама? Би трябвало *ChatGPT* да използва само невронната мрежа или ако използва допълнителни програми, би трябвало сам да ги създаде и да не разчита на помощта от програмисти. Тук проблемът не е, че програмистите помагат, а че за всеки конкретен проблем е нужна отделна програмка и не е възможно да се напишат такива програмки, които да покриват всички проблеми.

През 2015 г. се появи един хуманоиден робот, който се казваше *Sophia* (Retto, 2017). При този робот също имаше малко измама. От една страна, *Sophia* заблуждаваше с външността си, от друга страна – имаше дистанционно управление. *Sophia* охотно разговаряше с журналисти, но не беше ясно кога разговаря на базата на вградения в нея ИИ и кога разчита на човек оператор.

Всички дефиниции на ИИ, които са ни известни, разглеждат ИИ като устройство с памет (с вътрешно състояние), докато известните ни реализации са базирани на невронни мрежи и предполагат, че ИИ няма нужда от памет (*full observability*). Тоест има разминаване между дефинициите и реализациите.

Когато говорим за вътрешното състояние на ИИ, трябва да отбележим, че важното е вътрешното състояние на света, а вътрешното състояние на ИИ само отразява състоянието на света. Тоест вътрешното състояние на ИИ е „представата“ на ИИ за състоянието на света. Промяната на вътрешното състояние на ИИ трябва да е индуцирана от света. Например, ако нашият ИИ се „ядоса“, това ще е промяна във вътрешното му състояние, но тя трябва да е индуцирана от света. Нашият ИИ не би трябвало да се ядосва безпричинно. Бихме искали да направим ИИ, който не променя вътрешното си състояние безпричинно, а само като отражение на постъпилата информация от страна на света. Промяната би могла да настъпи и като резултат от разсъждения. Тоест новата информация може да не дойде директно от света, а да дойде със закъснение след известно обмисляне.

1.2.3.6 Формална дефиниция

Първата формална дефиниция на ИИ е публикувана в Hernández-Orallo (1998) и Hutter (2000). Дефиницията в Orallo (1998) има много несъвършенства, които са отбелязани в Dobrev (2019b). Поради тези несъвършенства можем да приемем, че първата формална дефиниция на ИИ е на Marcus Hutter.

Имаме една дребна забележка към дефиницията на Marcus Hutter. Той дефинира ИИ като най-добрата стратегия $AIXI$ ($AI\xi$). Това не е добре, най-малкото защото $AI\xi$ е неизчислима стратегия. Би трябвало да се каже, че ИИ е изчислима стратегия, която е „близо“ до най-добрата. Дори може да се наложи изискване за ефективност, защото ако една програма е прекалено неефективна, то тя не върши работа.

В Hutter (2007) той предлага една изчислима стратегия ($AIXItl$). Това е един конкретен алгоритъм и този алгоритъм също не може да бъде дефиниция на ИИ. Дори и самият алгоритъм $AIXItl$ да бъде приет за ИИ, той няма да бъде единственият алгоритъм, удовлетворяващ дефиницията на ИИ. Всеки друг алгоритъм, който изчислява същата стратегия, също би бил ИИ, особено ако работи по-ефективно (по-бързо) от $AIXItl$. Освен това не е нужно стратегията на ИИ да е съвсем същата като тази на $AIXItl$. Достатъчно е стратегията да е достатъчно добра.

Тази дребна забележка важи за дефиницията на Marcus Hutter, но не и за Dobrev (2005b и 2019b), защото там ИИ се дефинира като произволна програма с IQ, по-високо от определено ниво.

Има две подобрения на формалната дефиниция на ИИ, които са направени в настоящата дисертация и които подобряват всички формални дефиниции на ИИ, известни ни до момента.

1.2.3.7 Първо подобрение

Първото подобрение е, че в Hernández-Orallo (1998) и Hutter (2000) се предполага, че дължината на живота е ограничена. Същото предположение се прави и в Dobrev (2005b и 2019b). Има много причини, поради които е желателно да се избегне това предположение. Действително дължината на живота на естествения интелект има някакво ограничение, но то няма връзка с интелигентността. ИИ също може да има ограничение в дължината на живота, защото все някога ще решим да го изключим, но той не знае кога ще го изключим и би трябвало да работи стабилно до последния момент, без да се съобразява кога ще бъде изключен. Дори да допуснем, че дължината на живота е ограничена от някаква константа m , тази константа е толкова голяма, че е по-добре да я приемем за безкрайност.

Ако допуснем, че дължината на живота е ограничена, тогава ИИ ще бъде една крайна функция. Защо е важно да преминем от крайни към безкрайни функции? Защото, както казахме, нещата стават по-интересни, когато имаме безкрайност.

Очевидно Hernández-Orallo и Marcus Hutter споделят нашето желание да не се ограничава дължината на живота, защото в статиите Hutter (2006) и Hernández-Orallo (2011) има подобрен вариант на дефиницията, където няма горна граница. Там това е постигнато чрез коефициент на обезценка γ .

Коефициентът на обезценка γ определя понятието „алчност“. То ни казва доколко нашият ИИ ще се стреми към бърз успех или ще преследва успеха в по-далечна перспектива. Когато γ клони към нула, алчността се увеличава, а когато γ клони към единица – алчността намалява.

Може да се каже, че когато се използва коефициент на обезценка, за изчисляването на успеха се използва целият живот, но това е само формално. На практика от един момент нататък влиянието на живота върху оценката е пренебрежимо малко.

Това се илюстрира от следващата формула:

$$\forall \varepsilon > 0 \quad \forall \gamma \quad \exists m \quad \left(\left| 1 - \frac{\text{Success}(L_m)}{\text{Success}(L)} \right| < \varepsilon \right)$$

За всяко $\varepsilon > 0$ и за всяка обезценка γ съществува граница $m(\gamma)$, такава че частта от живота до момента $m(\gamma)$ определя частта от успеха $(1-\varepsilon)$, а оставащата част от успеха (ε) се определя от безкрайната част от живота, която е след момента $m(\gamma)$.

В тази дисертация сме избрали друг подход, при който се използва дължината на целия живот, и то тя се използва съществено. При нашия подход най-добрата стратегия използва границата, към която клони средната оценка, и избира най-доброто. По този начин най-добрата стратегия никога не прави фатални грешки. (При предишния подход фаталните грешки са възможни.)

Забележка: Това, че избираме стратегия, която не прави фатални грешки, не означава, че ако я следваме, ще изминем път, който е с най-добрия възможен среден успех. Означава нещо друго. След всяка стъпка ще има такъв път, по който ще можем да

продължим, но няма гаранция, че пътят, който в крайна сметка ще изминем, ще е такъв. Като пример ще дам една програма за игра на шах. Написахме тази програма със студентите като упражнение. Тя изчисляваше три хода напред и избираше най-добрия ход. Когато виждаше победа, това беше най-добрият ход, независимо дали победата е след един, два или три хода. Нашата програма започна да се държи много странно. Когато видеше, че печели, тя не матираше противника, а започваше да си играе с него като котка с мишка. Стоеше винаги на три хода от победата, но не бързаше да завърши играта. Щом добавихме малко алчност и направихме победата след един ход да е по-ценна от тази след два хода, този странен ефект веднага изчезна.

Въпросът е, ако имаме две действия, като и двете не водят до фатална грешка, кое от тях трябва да бъде предпочетено от най-добрата стратегия? В тази дисертация сме решили в този случай изборът да се прави с максимална алчност (да кажем, при безкрайно малко γ). Друг подход би бил, ако фиксираме алчността ($0 < \gamma < 1$). Този подход също не ни харесва, защото дори и при γ , което е много близо до единица, пак алчността на ИИ ще бъде твърде голяма, защото ще се обръща твърде голямо внимание на това кога във времето се е появил успехът.

Друг недостатък на подхода с алчността е, че ИИ ще е склонен излишно да протака, когато очаква да получи негативна оценка. Ние, хората, често избираме този подход и когато ни предстои нещо лошо, се опитваме да го отложим във времето. Все пак има случаи, когато предпочитаме да не протакаме. Например когато играем шах и видим, че ще загубим, ние не доиграваме докрай, а се предаваме.

Ето една идея как да дефинираме ИИ, който не е алчен и не протака излишно. Нека кажем, че ако два пътя водят до едно и също състояние, ще предпочетем този, който ни дава повече успех (сравняваме успеха, а не средния успех, което е съществено, защото двата пътя могат да имат различна дължина). Ако двата пътя ни дават еднакъв успех, ще предпочетем този, който е по-кратък.

По този начин, когато ИИ играе шах и види, че ще загуби, ще се предаде, защото ще има два възможни пътя, водещи до едно и също състояние, и при двата пътя оценката ще е „една загуба“.

1.2.3.8 Допълнителни параметри

Алчността е един допълнителен параметър на ИИ. Имаме и други допълнителни параметри като смелост и любопитство. Допълнителните параметри не определят еднозначно дали успехът ще се увеличи или намали. Има светове, в които е по-добре да си по-алчен, и други, в които алчността пречи.

При хората стойностите на тези допълнителни параметри не са еднакви. Има ситуации, в които оцеляват смелите, и други ситуации, в които печелят по-предпазливите. Ако хората бяха еднакви, то те биха били заплашени от изчезване, защото в определена ситуация всички те биха имали еднакво поведение. Благодарение на това, че хората са различни, те постъпват по различен начин и винаги част от популацията оцелява.

Има и основни параметри като памет и интелигентност, които еднозначно увеличават успеха на ИИ в произволен свят. Бихме могли да конструираме специален свят, който да наказва тези, които помнят повече или които са по-интелигентни, но в повечето светове паметта и интелигентността помагат.

Това е причината, поради която е добре допълнителните параметри да бъдат извадени като параметри на дефиницията. Така ще можем да си изберем дали искаме нашият ИИ да е по-смел или по-предпазлив. Основните параметри ще предполагаме, че са

максимално големи, като ограничения за тях ще бъдат само паметта и бързодействието на компютъра, който ще използваме, за да стартираме нашия ИИ.

1.2.3.9 Второ подобрене

Първото подобрене на дефиницията не е много съществено. Много по-важно е второто подобрене и то е, че един от най-важните параметри на дефиницията на ИИ е езикът за описание на света.

Трябва да признаем, че Marcus Hutter в (Hutter, 2007) е отбелязал, че универсалната машина на Тюринг е параметър на дефиницията:

*It (slightly) depends on the choice of the universal Turing machine.*⁴

Все пак той предполага, че светът се описва от изчислима функция и слага знак за равенство между езиките за програмиране и езиките за описание на светове. Всъщност възможните описания на света са много разнообразни и не се свеждат само до описание на изчислима функция.

В тази дисертация ще разгледаме различни описания на светове. Първо ще разгледаме най-стандартното представяне на света като детерминистична изчислима функция. След това ще добавим случайност, после ще добавим агенти и така ще получим най-различни езици за описание на светове.

1.2.3.10 Алтернативно мнение

Наскоро Илън Мъск написа отворено писмо (Musk, 2023), в което ни призова да забавим темпото и да спрем за шест месеца изследванията в областта на ИИ. Може би не всички изследвания, но поне да спрем с експериментите, които могат да доведат до техногенна катастрофа. Той по принцип е прав, но изпусне ли се веднъж духът от бутилката, е много трудно да се върне обратно. Съгласен съм, че трябва много да се внимава с експериментите, особено когато нямаме представа какъв точно може да е резултатът им. Все пак по-важното е първо да си зададем въпроса какво всъщност представлява ИИ и как ще живеем заедно с него от сега нататък.

1.2.3.11 Какво се случва в момента?

Ние сме на прага на появата на истинския изкуствен интелект (AGI). Това откритие ще преобърне нашия живот и ще го направи същевременно много лесен и съвсем безсмислен. Нашият живот силно ще се промени и въобще не сме сигурни, че това ще е за добро. (Няма да даваме дефиниция на това какво е добро и какво е лошо!)

Сега човечеството преживява момента, когато интелигентността на машините рязко скочи и хората действително се уплашиха. Става дума за скорошната поява на *ChatGPT*. Тази програма действително изумява със своята интелигентност, но това все още не е ИИ. Липсва още една съвсем малка крачка, за да стане *ChatGPT* истински ИИ. Тази липсваща крачка е описанието на скритото състояние. Точно тази последна крачка описваме в тази дисертация.

Ще попитате, щом това е последната крачка, която остава в пътя към AGI, тогава защо бързате да я направите? Защо не изчакате известно време?

Истината е, че появата на AGI е нещо неизбежно. Ако ние спрем и не участваме в процеса на създаването му, нашите колеги няма да спрат и ще го създадат.

⁴ Това зависи (донякъде) от избора на универсалната машина на Тюринг.

Някои казват, че щом появата на AGI е нещо неизбежно, тогава значи нищо не може да се направи. Всъщност има нещо, което ще бъде направено и това е нещо изключително важно. Ние сме поколението, което ще избере правилата на ИИ и това ще определи живота на хората за много години напред, може би завинаги.

Веднъж създаден AGI той ще работи по правилата на създателите си и тези правила няма да могат да бъдат променени, защото ще има само един AGI, който ще ни управлява и който няма да ни позволи да създадем втори AGI.

1.2.4 Постановка на задачата

Нека агентът има n възможни действия и m възможни наблюдения. Нека Σ и Ω са множествата на действията и на наблюденията. Две от наблюденията ще са специални. Това ще са *good* и *bad*, които ще дават наградите 1 и -1. Останалите наблюдения от Ω ще дават награда 0.

Ще добавим още едно специално наблюдение и това ще е наблюдението *finish*. Агентът никога няма да вижда това наблюдение ($finish \notin \Omega$), но то ще ни е нужно при дефиницията на модел на света. Моделът ще предсказва *finish*, когато се е счупил и повече нищо не може да предскаже. Няма да гледаме на наблюдението *finish* като край на живота, а като скок в неизвестното. Наблюдението *finish* ще дава награда -1, защото искаме нашият ИИ да избягва такива скокове в неизвестното.

Дефиниция 1: Дървото на всички възможности е едно безкрайно дърво. Върховете, които са на четна дълбочина и не са листа, ще наричаме „върхове за действие“, а тези, които са на нечетна дълбочина, ще наречем „върхове за наблюдение“. От всеки връх за действие излизат n стрелки, на които съответстват n -те възможни действия на агента. От всеки връх за наблюдение излизат $m+1$ стрелки, на които съответстват m -те възможни наблюдения на агента и наблюдението *finish*. Стрелката, която съответства на *finish*, води до листо. Останалите стрелки водят до върхове, които не са листа.

Дефиниция 2: „Свят“ ще наричаме тройката $\langle S, s_0, f \rangle$, където:

1. S – крайно или изброимо множество от вътрешните състояния на света.
2. $s_0 \in S$ – началното състояние на света.
3. $f: S \times \Sigma \rightarrow \Omega \times S$ – функция, която на състояние и действие връща наблюдение и ново състояние на света.

Функцията f не може да върне наблюдението *finish* (то се предсказва само когато f не е дефинирана и когато няма следващо състояние на света). Дали функцията f е изчислима, детерминирана или тотална? Отговорът на всеки един от тези три въпроса може да е „Да“, а може да е „Не“.

Дефиниция 3: Детерминирана стратегия на агента е функция, която на всеки връх за действие ни съпоставя по едно действие.

Дефиниция 4: Недетерминирана стратегия на агента е функция, която на всеки връх за действие ни съпоставя едно или повече възможни действия.

Когато в един връх (момент) стратегията ни дава всички възможни действия, ще казваме, че в този момент стратегията не знае какво да прави. Няма да правим разлика между агент и стратегия на агента. Обединение на две стратегии ще наричаме стратегията, която се получава, когато избираме една от двете стратегии и я изпълняваме, без да я сменяме. Ако разрешим избраната стратегия да се сменя, би се получило нещо друго.

Дефиниция 5: „Живот“ ще наричаме път в дървото на всички възможности, започващ от корена.

Всеки живот може да се представи чрез редицата от действия и наблюдения:

$$a_1, o_1, \dots, a_t, o_t, \dots$$

Няма да правим разлика между краен живот и връх от дървото на всички възможности, защото има взаимно еднозначно съответствие между двете.

Дефиниция 6: Дължината на живота ще бъде t (броят на наблюденията). Тоест дължината на живота ще е дължината на пътя върху двете.

Дефиниция 7: Завършен живот ще е такъв, който не може да се продължи. Тоест това ще е безкраен живот или живот, завършващ с наблюдението *finish*.

Когато пуснем един агент в един свят, резултатът ще е завършен живот. Ако агентът е недетерминиран, тогава резултатът не е единствен. Същото, ако светът е недетерминиран.

1.2.5 Оценка

Искаме да определим най-добрата стратегия на агента. За целта ни трябва оценка на живота. Тази оценка ще ни даде една линейна наредба, която за всеки два живота ще ни каже кой е по-добрият.

Първо, ще кажем какъв е успехът на живота L . Когато животът е краен, ще преброим колко пъти сме наблюдавали *good* – това число ще означим с $L_{good}(L)$. Аналогично за *bad* и *finish*. По този начин успехът за краен живот ще бъде:

$$Success(L) = \frac{L_{good}(L) - L_{bad}(L) - L_{finish}(L)}{|L|}$$

Ще означим с L_i началото на живота L , което е с дължина i . За безкраен живот L ще дефинираме $Success(L)$ като границата на $Success(L_i)$, когато i клони към безкрайност. Ако тази редица не е сходяща, ще вземем средното между точната долна и точната горна граница.

$$Success(L) = \frac{1}{2} \cdot \left(\liminf_{i \rightarrow \infty} (Success(L_i)) + \limsup_{i \rightarrow \infty} (Success(L_i)) \right)$$

По този начин на всеки живот съпоставихме едно число, което е в интервала $[-1, 1]$ и което е успехът на този живот. Дали успехът на живота да не бъде оценката, която търсим? Това не е добра идея, защото, ако в един свят няма фатални грешки, тогава на най-добрата стратегия ще ѝ е все едно какво играе. Ще има един максимален успех и този максимален успех винаги ще може да бъде постигнат, без значение колко грешки са направени в началото. Бихме искали, ако има две възможности, които в безкрайност дават еднакъв успех, най-добрата стратегия да предпочете тази възможност, която по-скоро ще даде положителен резултат. Затова дефинираме оценка на завършен живот по следния начин:

Дефиниция 8: Оценката на безкрайния живот L ще бъде редицата, започваща с успеха на живота и продължена с наградите, получени на i -тата стъпка:

$$Success(L), reward(o_1), reward(o_2), reward(o_3), \dots$$

Дефиниция 9: Оценката на крайния завършен живот L ще бъде същата редица, но за $i > t$ членовете $reward(o_i)$ ще бъдат заместени със $Success(L)$:

$$Success(L), reward(o_1), \dots, reward(o_t), Success(L), Success(L), \dots$$

(Тоест наблюденията, които са след края на живота, ще получат очакване за наградата, което е равно на успеха на крайния завършен живот.)

Ще сравняваме две оценки, като вземем първата разлика. Тоест първата цел на най-добрата стратегия ще бъде успехът на целия живот, но втората цел ще бъде максимално бърз резултат.

1.2.6 Очакваната оценка

Дефиниция 10: За всяка детерминирана стратегия P ще определим $grade(P)$, което ще бъде очакваната оценка на живота, при условие че се изпълни тази стратегия.

Ще определим очакваната оценка за всеки връх v , при условие че някак сме стигнали до v и от този момент нататък изпълняваме стратегията P . Очакваната оценка на P ще бъде оценката, която сме съпоставили на корена.

Ще опишем грубо как на върховете се съпоставят очакваните оценки. След това ще опишем подробно частния случай, когато се търси най-добрата оценка – тази, която е очакваната оценка на най-добрата стратегия.

Грубо описание:

1. Нека v е връх за действие.

Тогава оценката на v ще бъде оценката на прекия наследник на v , който отговаря на действието $P(v)$.

2. Нека v е връх за наблюдение.

2.1. Нека има един възможен свят, който е модел на v .

Ако изпълняваме P в този свят, ще получим един възможен живот. Тогава оценката на v ще бъде оценката на този живот.

2.2. Нека има много възможни светове.

Тогава всеки свят ни дава по един възможен живот и оценка на v се получава като средното от оценките на възможните животи.

Следва подробно описание на най-добрата стратегия. Основната разлика е, че когато v е връх за действие, най-добрата стратегия винаги избира максимума от очакваните оценки на преките наследници.

1.2.7 Най-добрата стратегия

Както вече казахме, за да имаме очакване за успеха на агента, трябва да имаме някакво предположение за това какъв е светът. Ще предполагаме, че светът може да се опише чрез някакъв език за описание на светове.

Нека вземем стандартния език за описание на светове. Това е езикът, при който светът се описва с изчислима функция (така е в Hutter, 2000). За да опишем изчислимата функция f , ще използваме машина на Тюринг. Началното състояние на света ще опишем като крайна дума над азбуката на машината на Тюринг. Получаваме изчислим и детерминиран свят, който в общия случай не е тотален.

Дефиниция 11: Свят със сложност k ще бъде свят, в който:

1. Функцията f се описва с машина на Тюринг с k състояния.
2. Азбуката на машината съдържа $k+1$ символа $(\lambda_0, \dots, \lambda_k)$.
3. Началното състояние на света е дума с не повече от k букви. Азбуката е $\{\lambda_1, \dots, \lambda_k\}$, т.е. азбуката на машината без празния символ λ_0 .

Тук за три различни неща използваме едно и също k , но няма нужда да използваме различни константи.

Ще кажем коя е най-добрата стратегия за световите, които са със сложност k (важно е, че тези светове са крайно много). За целта на всеки връх за наблюдение ще съпоставим неговата най-добра оценка (очакваната оценка, при условие че оттам нататък се изпълнява най-добрата стратегия).

Нека имаме живота: $a_1, o_1, \dots, a_t, o_t, a_{t+1}$.

Нека този живот минава през върховете: $v_0, w_1, v_1, \dots, w_t, v_t, w_{t+1}$.

Тук v_0 е коренът, v_i са върхове за действие, а w_i са върхове за наблюдение.

За v_t ще видим колко модела със сложност k има той.

Дефиниция 12: Един детерминиран свят е модел на v_t , ако в този свят агентът би достигнал до v_t , ако извърши съответните действия (a_1, \dots, a_t) . Всеки връх за действие има едни и същи модели със своите преки наследници.

Дефиниция 13: Най-добрата стратегия за световите, които са със сложност k , ще бъде тази, която винаги избира най-добрата оценка (измежду най-добрите оценки на преките наследници).

Дефиниция 14: Най-добрата оценка на върха w_{t+1} (за световите със сложност k) се определя по следния начин:

Първи случай. Върховете v_t и w_{t+1} нямат модел със сложност k .

Тогава най-добрата оценка на w_{t+1} ще бъде *undef*. В този случай стратегията няма да знае какво да прави (в цялото поддърво на v_t), защото най-добрата оценка на всички наследници ще бъде *undef*.

Ако не искаме да въвеждаме оценка *undef*, можем да използваме най-малката възможна оценка, което е редицата от минус единици. Когато избираме максимума, го избираме между върховете, които не са *undef*. Ако заменим *undef* с възможно най-малката оценка, резултатът ще е същият.

Втори случай. Върховете v_t и w_{t+1} имат един модел със сложност k .

Нека D е този модел. В този случай има континуум много пътища, минаващи през w_{t+1} , такива че D е модел на всичките тези пътища. Ще изберем от тези пътища (завършени животи) множеството на най-добрите. Оценката, която търсим, ще бъде оценката на тези най-добри пътища. На всеки един от тези пътища съответства детерминирана стратегия на агента. Тези стратегии ще наречем „най-добрите стратегии, минаващи през w_{t+1} “.

Ще построим множеството на най-добрите детерминирани стратегии по следния начин: Нека P_0 е множеството на всички стратегии, които водят до w_{t+1} . Взимаме успеха на всяка една от тях в света D . Взимаме подмножеството P_1 от тези стратегии, в които се постига максималният успех. Намаляваме P_1 , като взимаме тези стратегии, при които за $reward(o_{t+2})$ се постига максимум, и получаваме P_2 . След това повтаряме процедурата за всяко $i > 2$. По този начин получаваме множеството на най-добрите детерминирани стратегии P . (Най-добрите от тези, които минават през w_{t+1} . Също така най-добрите по пътищата, минаващи през w_{t+1} , а за останалите пътища няма значение как се държи стратегията.)

$$P = \bigcap_{i=0}^{\infty} P_i$$

Множество P можем да си го мислим като една недетерминирана стратегия. Нека вземем някое $p \in P$. По този начин ще получим и най-добрата оценка:

$$Success(p), reward(o_{t+1}), reward(o_{p,t+2}), reward(o_{p,t+3}), \dots$$

Тук пропускаме членовете $reward(o_i)$ при $i \leq t$, защото те са определени еднозначно от v_t . Следващият член зависи от w_{t+1} и D , но не зависи от p . Оставащите членове зависят от p .

Горната формула можем да запишем и по този начин:

$$\max_{p \in P_0} Success(p), reward(o_{t+1}), \max_{p \in P_1} reward(o_{p,t+2}), \max_{p \in P_2} reward(o_{p,t+3}), \dots$$

Трети случай. Върховете v_t и w_{t+1} имат краен брой модели със сложност k .

Нека M е множеството на тези модели. Отново имаме континуум много пътища, минаващи през w_{t+1} , такива че за всеки един от тях някой свят от M му е модел. Тези пътища отново образуват дърво, но във втория случай разклоненията бяха само заради различна стратегия на агента, а тук може да има разклонения заради различен модел на света. Отново имаме континуум много детерминирани стратегии, но те вече не съответстват на пътища, а на поддървета, защото може да има разклонение по модела. Отново ще търсим множеството на най-добрите детерминирани стратегии и търсената оценка ще бъде тяхната средна оценка (средната оценка в M).

Отново ще построим множествата от стратегии P_i . Тук P_1 ще бъде множеството от стратегиите, при които се постига максимумът на средния успех. Съответно P_2 ще бъде множеството на тези от тях, при които се постига максимумът на средното на $reward(o_{t+2})$ и т.н. Получената оценка ще изглежда по следния начин:

$$\max_{p \in P_0} \sum_{m \in M} q_m \cdot Success(m, p), \sum_{m \in M} q_m \cdot reward(o_{m,t+1}), \max_{p \in P_1} \sum_{m \in M} q_m \cdot reward(o_{m,p,t+2}), \dots$$

Ако вземем някое $p \in P$, тогава получената оценка ще изглежда така:

$$\sum_{m \in M} q_m \cdot Success(m, p), \sum_{m \in M} q_m \cdot reward(o_{m,t+1}), \sum_{m \in M} q_m \cdot reward(o_{m,p,t+2}), \dots$$

Тук q_i са теглата на световите, които са нормализирани, за да се превърнат във вероятности. В случая предполагаме, че световите имат еднакво тегло. Тоест:

$$q_i = \frac{1}{|M|}$$

■

Това, което описахме, прилича на алгоритъм, но не е алгоритъм, а дефиниция, защото вътре има неизчислими стъпки. Описаната стратегия е добре дефинирана, макар и неизчислима. Как чрез най-добрата оценка за сложност k ще получим най-добрата оценка за всяка сложност?

Дефиниция 15: Най-добрата оценка на върха v ще бъде границата на най-добрите оценки на върха v за световите, които са със сложност k , когато k клони към безкрайност.

Как ще дефинираме граница на редица от оценки? Числото, което е на позиция i , ще бъде границата от числата, които са на позиция i . Когато редицата е разходяща, ще вземем средното между точната долна и точната горна граница.

Дефиниция 16: Най-добрата стратегия ще бъде тази, която винаги избира действие, което води до максимума, получен от най-добрите оценки на преките наследници.

С какво най-добрата стратегия е по-добра от най-добрата стратегия за светове със сложност k ? Първата стратегия знае какво да прави във всеки връх, докато втората стратегия в повечето върхове не знае какво да прави, защото в тях няма нито един модел със сложност k . Първата стратегия може да даде по-добро решение от втората дори и за върховете, за които втората стратегия знае какво да прави, защото първата стратегия разглежда и моделите със сложност, по-голяма от k . На пръв поглед не използваме бръснача на Окам, защото всички модели имат еднаква тежест, но всъщност използваме бръснача на Окам, защото по-простите светове се изчисляват от повече машини на Тюринг, тоест те имат по-голяма тежест.

1.2.8 Дефиниция на ИИ

Дефиниция 17: ИИ ще бъде изчислима стратегия, която е достатъчно близо до най-добрата.

Тук трябва да кажем какво значи една стратегия да е близо до друга стратегия и колко е достатъчно близо. Ще казваме, че две стратегии са близки, когато очакваните оценки на двете стратегии са близки.

Дефиниция 18: Нека A и B са две стратегии и $\{a_n\}$ и $\{b_n\}$ са техните очаквани оценки. Тогава разликата между A и B ще бъде $\{\varepsilon_n\}$, където:

$$\varepsilon_n = \sum_{i=0}^n \gamma^i (a_i - b_i) = \varepsilon_{n-1} + \gamma^n (a_n - b_n)$$

Тук γ е коефициент на обезценка. Нека $\gamma=0.5$. Добавили сме коефициент на обезценка, защото искаме когато две стратегии дълго време се държат еднакво, тогава двете стратегии да са близки. Колкото по-далеч във времето се появи разликата, толкова по-малко влияние ще има тя.

Когато n се увеличава, тогава $|\varepsilon_n|$ може да расте или да намалява. Дефиницията е направена така, защото искаме разликата да е малка, когато очакваната оценка на стратегията A кръжи около очакваната оценка на B . Тоест, ако за $(n-1)$ по-голямата е очакваната оценка на A , а за n по-голяма е тази на B , тогава в ε_n увеличението и намалението се компенсират едно друго.

Дефиниция 19: Ще казваме, че $|A-B| < \varepsilon$, ако $\forall n \ |\varepsilon_n| < \varepsilon$.

Ако $\forall \varepsilon \ |A-B| < \varepsilon$, тогава очакваната оценка на A е равна на очакваната оценка на B .

1.2.9 Програма, удовлетворяваща дефиницията

Ще опишем алгоритъм, който представлява изчислима стратегия. На всеки връх за действие съответства незавършен живот и алгоритъмът ще ни даде действие, с което този живот да бъде продължен. Този алгоритъм ще се състои от две стъпки.

1. Алгоритъмът ще отговори на въпроса „Какво става?“. Това ще стане, като намери първото k , за което незавършеният живот има модел. Също така алгоритъмът ще намери множеството M (множеството на всички модели на незавършения живот, които са със сложност k). За съжаление, това е неизчислимо. За да стане изчислимо, ще търсим ефективни модели със сложност k .

Дефиниция 20: Ефективен модел със сложност k ще бъде свят със сложност k (дефиниция 11), при който машината на Тюринг използва не повече от $(1000.k)$ стъпки, за

да направи една стъпка от живота (да изчисли следващото наблюдение и следващото вътрешно състояние на света). Когато машината направи повече от $(1000.k)$ стъпки, тогава моделът извежда наблюдението *finish*.

Тук числото 1000 е някакъв параметър на алгоритъма, но приемаме, че този параметър не е много съществен. Ако един връх има модел със сложност k , но няма ефективен модел със сложност k , тогава $\exists n (n > k)$, такова че върхът има ефективен модел със сложност n .

2. Алгоритъмът ще отговори на въпроса „Какво да правя?“. За целта ще проиграем h стъпки в бъдещето по всички модели от M и по всички възможни действия на агента. Тоест ще обходим едно крайно поддърво и за всеки връх на поддървото ще изчислим *best* (това е най-добрата очаквана оценка до листо). След това ще изберем действие, което води до максимума по *best*.

Дефиниция 21: Частично поддърво на върха v_t по M на дълбочина h ще бъде поддървото на v_t , състоящо се от върховете, които са на дълбочина не повече от $2h$ и които имат модел в M .

Дефиниция 22: Оценка до листо на върха v_{t+i} до листото v_{t+j} ще бъде:

Първи случай. Ако $j=h$, тогава това ще бъде редицата:

$Success(v_{t+j}), reward(o_{t+i+1}), \dots, reward(o_{t+j})$

Втори случай. Ако $j < h$, тогава това ще бъде същата редица, но удължена с $(h-j)$ пъти $Success(v_{t+j})$. Целта на това удължаване е дължината на оценката до листо винаги да бъде $(h-i+1)$.

Дефиниция 23: Най-добрата очаквана оценка до листо (*best*):

1. Нека v_{t+i} е връх за действие.

1.1. Ако v_{t+i} е листо, тогава $best(v_{t+i})$ е оценката до листо на върха v_{t+i} до листото v_{t+i} .

1.2. Ако v_{t+i} не е листо, тогава:

$$best(v_{t+i}) = \max_{a \in \Sigma} best(w_a)$$

Тук с w_a сме отбелязали прекия наследник на v_{t+i} , получен след действието a . Аналогично по-долу за v_o .

2. Нека w_{t+i} е връх за наблюдение, тогава:

$$best(w_{t+i}) = \sum_{o \in \Omega'} p_o \cdot (reward(o) \text{ insert_at_1_in } best(v_o))$$

Тоест взимаме най-добрата очаквана оценка от преките наследници и я удължаваме с едно, като вмъкваме на първа позиция $reward(o)$. Тук $\Omega' = \Omega \cup \{finish\}$, а с p_o сме означили вероятността следващото наблюдение да е o . Нека с $M(v)$ да означим множеството на моделите на v . Тогава:

$$p_o = \frac{(\sum_{m \in M(v_o)} q_m)}{(\sum_{m \in M(w_{t+i})} q_m)} = \frac{|M(v_o)|}{|M(w_{t+i})|}$$

Тук q_m са теглата на моделите. Последното равенство се получава от предположението, че тези тегла са равни. Там, където няма модел, съответното p_o е нула и няма нужда $best(v_o)$ да се изчислява.

■

Покажахме как се изчислява най-добрата частична стратегия. Това ли ще е стратегията на нашия алгоритъм? Отговорът ще е „Не“, защото искаме да допускате известен толеранс.

Ако две стратегии се различават незначително по първата координата на оценката си, тогава, ако леко увеличим h , е много вероятно подредбата да се промени. Затова една стратегия ще бъде предпочетена, ако тя е съществено по-добра (тоест разликата при някоя от координатите е повече от ε).

Ще дефинираме най-добрата частична стратегия с толеранс ε и това ще е стратегията на нашия алгоритъм.

1.2.10 Толеранс ε

Ще модифицираме горния алгоритъм, като променим функцията $best$. Тази функция връщаше най-добрата оценка, а сега ще връща множеството на най-добрите оценки с толеранс ε .

Как ще променим търсенето на максимална оценка в множество от оценки? Преди се гледаше първата координата и се взимаха оценките, при които тази координата е най-голяма, после от тях се взимаха тези оценки, при които втората координата е най-голяма, и т.н. Накрая се получаваше само една оценка. След модификацията ще вземем тези оценки, при които първата координата е най-голяма, и тези, които са на разстояние ε от максимума.

Нека E_0 е стартовото множество от оценки. Нека в E_0 има n оценки и всичките са с дължина m . Ще построим редицата от множества от оценки E_0, \dots, E_m ($E_{i+1} \subseteq E_i$) и последното множество E_m ще бъде търсеното множество на най-добрите оценки с толеранс ε . Нека $E_0 = \{G_1, \dots, G_n\}$ и $G_j = \{g_{j0}, \dots, g_{jm}\}$. Ще построим и целевата оценка α ($\alpha = \{\alpha_0, \dots, \alpha_m\}$). Търсеното множество от оценки E_m , ще са оценките на разстояние ε от α .

Дефиниция 24: Целевата оценка α и търсеното множество E_m се получават по следния начин:

$$\begin{aligned}\alpha_0 &= \max_{G_j \in E_0} g_{j0} \\ E_1 &= \{ G_j \in E_0 \mid \alpha_0 - g_{j0} < \varepsilon \} \\ \alpha_1 &= \max_{G_j \in E_1} g_{j1} \\ E_2 &= \{ G_j \in E_1 \mid (\alpha_0 - g_{j0}) + \gamma(\alpha_1 - g_{j1}) < \varepsilon \}\end{aligned}$$

Тук γ отново е коефициент на обезценка. Така модифицирахме начина, по който се изчислява максимумът. Трябва да модифицираме и сумата на оценки.

Сега оценките са заменени с множества от оценки. Ще направим всички възможни комбинации и за всяка една комбинация ще изчислим сумата. Полученото множество ще бъде множеството от всички суми от всички възможни комбинации.

Остава да изберем следващия ход. Ще вземем множествата от оценки, които ни дава функцията *best* за преките наследници на v_i . Ще направим обединението на тези множества и ще изчислим множеството на най-добрите оценки с толеранс ε . Ще изберем някое от действията, които ни водят към една от тези най-добри оценки.

1.2.11 Дали това е ИИ?

Дали описаният по-горе алгоритъм удовлетворява нашата дефиниция на ИИ? Първо ще кажем, че този алгоритъм зависи от параметрите h и ε . За да намалим броя на параметрите, ще приемем, че ε е функция на h . Например $\varepsilon = h^{-0.5}$.

Твърдение 1: При достатъчно голямо h описаният алгоритъм е достатъчно близо до най-добрата стратегия.

Нека най-добрата стратегия е P_{best} , а стратегията, изчислена от описания алгоритъм с параметър h , е P_h . Тогава горното твърдение може да се запише така:

$$\forall \varepsilon > 0 \exists n \forall h > n (|P_{best} - P_h| < \varepsilon)$$

Не можем да докажем това твърдение, но можем да приемем, че когато h клони към безкрайност, описаната стратегия клони към най-добрата стратегия за световите, които са със сложност k . Когато t клони към безкрайност, k ще достигне сложността на света или ще клони към безкрайност. Тези разсъждения ни карат да си мислим, че горното твърдение е вярно.

1.2.12 Свят със случайност

Първият език за описание на светове, който разгледахме, описва детерминирани светове. Ако в света има някаква случайност, тогава описанието на този език ще е много далеч от истината. Ще добавим случайност към езика за описание на светове. По този начин ще получим нов език, който ще е много по-добър и по-изразителен.

При новия език светът отново ще се описва чрез изчислима функция, но тази функция ще има още един аргумент и това ще е случайността. Случайност ще наричаме резултата от хвърлянето на един зар. Нека сложността на света да е k . Тогава зарът ще има k възможни резултата. Вероятностите да се падне всеки един от тези резултати ще бъдат p_1, \dots, p_k .

Дефиниция 25: Модел на живота до момента t със сложност k ще бъде свят със сложност k и случайност с дължина t . Ще искаме този живот да се генерира от този модел и тази случайност. Случайността ще е произволна дума R с дължина t . Буквите на R ще са от азбуката на машината на Тюринг без λ_0 .

Теглото на модела е вероятността да се случи R .

Дефиниция 26: Теглото на модела ще бъде $p_1^{L_{\lambda_1}(R)}, \dots, p_k^{L_{\lambda_k}(R)}$.

Вероятностите p_1, \dots, p_k на модела ще определим така, че вероятността да се случи R да е максимална:

$$p_i = \frac{L_{\lambda_i}(R)}{|R|}$$

Тоест ще имаме модели с малко тегло, при които вероятността да се случи точно този живот е много малка, и модели с голямо тегло, при които тази вероятност е по-голяма.

1.2.13 Дефиниция със случайност

По същия начин, както направихме по-горе, ще дефинираме най-добрата стратегия за моделите, които са със сложност k . (Тук е важно, че моделите имат различно тегло.) Ще направим стратегията, която е границата, когато k клони към безкрайност, и това ще е най-добрата стратегия. Отново дефиницията на ИИ ще бъде изчислима стратегия, която е достатъчно близо до най-добрата стратегия.

Твърдение 2: Двете дефиниции на ИИ съвпадат.

Тоест най-добрата стратегия за световите без случайност е същата като най-добрата стратегия за световите със случайност. За да докажем горното, ни е нужно първо да докажем:

Твърдение 3: Ако имаме произволна дума ω над азбуката $\{0, 1\}$, в която единиците са с вероятност p , и ако направим естественото продължение на тази дума, то следващата буква ще е единица с вероятност p .

Какво е естествено продължение? Нека вземем първата (най-простата) машина на Тюринг, която генерира ω . Естественото продължение ще наричаме продължението, което ще се генерира от тази машина на Тюринг.

Не можем да докажем твърдение 3, но ще дадем две идеи за неговото доказателство.

Първата идея е практически експеримент. Ще напишем програма, която намира естественото продължение на редица, и ще експериментираме. Ще дадем на програмата различни думи ω , в които 1 е с вероятност p . Ще видим какво е продължението и ще изчислим средната вероятност от тези експерименти. Ако експериментите са много и ако получената средна вероятност е p , можем да предполагаме, че твърдение 3 е вярно.

Втората идея за доказателство е теоретична. Нека имаме една изчислима функция f от \mathbb{N} в \mathbb{N} . Нека сме тръгнали от числото n . Получаваме редицата $f^i(n)$. Ще превърнем тази редица в редицата от нули и единици b_i . Числото b_i ще е нула iff $f^i(n)$ е четно. Нека ω е начало на b_i . Какво е очакването ни за следващия елемент на b_i ?

1 сл. Редицата b_i е циклична и има вида $\omega_1\omega_2^*$. Нека ω е по дълга от ω_1 . Тогава има начало на ω_2 , което е част от ω , и за него единиците са с вероятност p .

2 сл. Редицата $f^i(n)$ има дълго начало, в което нечетните числа са с вероятност p . Няма причини да очакваме тази вероятност да се промени.

1.2.14 Програма със случайност

Ще направим програма, която удовлетворява дефиниция на ИИ, която е направена на базата на модели със случайност. Ще направим тази програма по същия начин, както я направихме по-нагоре, но ще има някои разлики.

Няма да търсим първото k , за което има модел до момента t със сложност k , защото такъв модел ще има дори и при съвсем малко k . Вместо това ще предполагаме, че k е фиксирано и че k е параметър на алгоритъма.

Първата стъпка ще бъде да намерим всички модели със сложност k на върха v_t . Втората стъпка ще бъде да обикаляме на дълбочина h частично поддърво на върха v_t по всички намерени модели, по всички възможни действия на агента и по всички случайности R_1R_2 , където R_1 е случайността на модела, а R_2 е случайността след t . Тук R_1 е фиксирана (определя се от модела), а R_2 пробягва всички възможности.

Аналогично на твърдение 1 ще направим:

Твърдение 4: При достатъчно големи k и h описаният алгоритъм е достатъчно близо до най-добрата стратегия.

Твърдим, че при достатъчно големи параметри двата алгоритъма изчисляват приблизително една и съща стратегия, но дали тези два алгоритъма са еднакво ефективни?

На практика и двата алгоритъма са безкрайно неефективни, но все пак вторият алгоритъм е много по-ефективен от първия. Ще разгледаме три случая.

1. Нека имаме прост детерминиран свят. Прост в смисъл, че е със сложност k , където k е малко. В този случай първият алгоритъм ще е малко по-ефективен, защото бързо ще намери модела. Вторият алгоритъм ще намери същия модел, защото детерминираният модел е подмножество на недетерминирания.

2. Нека имаме детерминиран свят, който не е прост, т.е. той е с голямо k . В този случай на първия алгоритъм ще му е нужно ужасно много време, за да намери модел на света. Вероятно той няма да намери истинския модел на света, а едно по-просто обяснение. Това по-просто обяснение ще е модел на живота до t , но след още няколко стъпки моделът ще сгреша. Вторият алгоритъм също ще намери по-просто обяснение на света, но то ще е недетерминирано. И двата алгоритъма ще предсказват бъдещето с някаква грешка, но описанието, което включва случайност, ще е по-добро и по-точно. Освен това сложността на описанието със случайност ще е много по-малка.

3. Нека имаме свят със случайност. В този случай вторият алгоритъм има съществено преимущество. Той ще намери недетерминирания модел на света и ще започне да предсказва бъдещето по най-добрия възможен начин. На пръв поглед изглежда сякаш първият алгоритъм въобще няма да се справи, но това не е така. И той ще се справи, макар и много по-бавно. Недетерминираният модел се състои от изчислима функция f и случайност R . Съществува изчислима функция g , която генерира R . Композицията на f и g ще бъде детерминиран модел на света в момента t . Разбира се, след още няколко стъпки g ще се размине от действителната случайност и $f \circ g$ вече няма да е модел на света. Тогава ще трябва да търсим нова функция g . Тоест възможно е чрез детерминистична функция да опишем свят със случайност, но това описание е много измъчено и работи само до някой момент t . Недетерминистичният модел ни дава описание, което работи за всяко t .

Изводът е, че изборът на език за описание на света е много важен. Може би тези два езика дават една и съща дефиниция на ИИ, но програмите, получени на базата на двата езика, имат съществено различна ефективност.

1.2.15 Свят с много агенти

Светът със случайност може да се разглежда като свят с един агент, който играе случайно. Нека допуснем, че светът има много агенти и те са разделени на три вида:

1. Приятели, които ни помагат.
2. Врагове, които се стремят да ни попречат.
3. Такива, които играят случайно.

Нека броят на агентите е a (без да броим главния герой). Ще допуснем, че всеки агент има k възможни хода (k е сложността на света). Ще предположим, че първи играе главният герой (това сме ние), а след него играят останалите агенти, като редът, по който играят, е фиксиран. Предположим, че всеки агент вижда всичко (вижда вътрешното състояние на света, вижда модела, включително броя на агентите и това кой е приятел и кой е враг, и вижда как вече са играли тези агенти, които играят преди него). Ще

предполагаме още, че агентите са много умни и могат да изчислят кой е най-добрият и кой е най-лошият ход.

Моделът на света отново ще бъде машина на Тюринг, но с повече аргументи (вътрешното състояние на света и хода на главния герой плюс ходовете на всички останали агенти). Моделът ще включва още и това кой ни е приятел и кой ни е враг. Моделът на живота до момента t ще включва още и ходовете на всичките a агента за всичките t стъпки.

Отново ще направим дефиниция на ИИ на базата на този нов, по-сложен език. Отново ще направим предположението, че това е същата дефиниция. Ще направим и програма, която търси модел на света в множеството на световите с много агенти. Ще видим, че сега езикът е много по-изразителен и че ако в света имаме поне един опонент, то този начин за описание на света е много по-адекватен и съответно програмата, която сега сме направили, е много по-ефективна.

1.2.16 Заключение

Разгледахме три езика за описание на света. На базата на всеки един от тях направихме дефиниция на ИИ и предположихме, че в трите случая дефиницията е една и съща. Ще направим едно още по-силно предположение.

Твърдение 5: Дефиницията на ИИ не зависи от езика за описание на света, на базата на който сме направили тази дефиниция.

Това твърдение не можем да го докажем, макар че предполагахме, че то е вярно. Също така предполагахме, че то не може да бъде доказано (подобно на тезиса на Чърч).

Въпреки че предположихме, че дефиницията на ИИ не зависи от езика за описание на света, предполагахме, че от този език силно зависи програмата, която удовлетворява тази дефиниция. При сравнението между първите два езика се видя, че вторият е много по-експресивен и полученният чрез него ИИ е много по-ефективен.

Ще разгледаме още един език за описание на светове. Това е езикът, описан в Dobrev (2022b, 2023). В този език се дефинира понятието „алгоритъм“ и чрез това понятие много по-ефективно се описва света. С понятието „алгоритъм“ ние можем да планираме бъдещето. Нека вземем като пример следното: „Ще чакам автобуса, докато дойде. После ще отида на работа и ще седя там до края на работното време“. Тези две изречения описват бъдещето чрез изпълнение на алгоритми. Ако ще предвиждаме бъдещето само като обхождаме h възможни стъпки, то това h ще трябва да стане неприемливо голямо.

Езикът, описан в Dobrev (2022b, 2023), е много по-експресивен и той дава надежда, че чрез него ще може да се направи програма, която да е ИИ и която да е достатъчно ефективна, за да може да работи в реално време.

1.2.17 Благодарности

Искам да благодаря на моя колега Иван Сосков. Той е човекът, с когото преди години обсъждах ефективността на ИИ. Искам да благодаря и на моите колеги Димитър Димитров и Йоан Карадимов. Идеята за тази част от дисертацията възникна по време на един разговор с тях. Искам да се извиня на Marcus Hutter и Shane Legg, защото в статията си Dobrev (2013a) несправедливо ги обвиних, че са използвали моя статия, без да я цитират. По-късно, когато внимателно прочетох статията на Marcus Hutter (Hutter, 2000), разбрах, че там той е публикувал основните идеи много преди мен.

2 Как да го направим?

2.1 Език за описание на светове

Ще сведем задачата за създаването на ИИ към задачата за намирането на подходящия език за описание на света. Този език няма да е език за програмиране, защото езиците за програмиране описват само изчислими функции, докато този език ще опише малко по-широк клас от функции. Друга особеност на този език ще е, че при него описанието ще може да бъде разбито на отделни модули. Това ще ни позволи да търсим описанието на света автоматично, като го откриваме модул по модул. Подходът ни за създаването на този нов език ще бъде да започнем от един конкретен свят и да напишем описанието на тази конкретен свят. Идеята ни е, че езикът, който може да опише този конкретен свят, ще е подходящ за описанието на произволен свят.

2.2 Въведение

Тази дисертация представя един нов подход в изследването на ИИ. Това е *Event-Driven (ED)* подходът. Идеята, която стои зад *ED* подхода, е, че моделът не трябва да поема цялата входно-изходна информация, а трябва да отрази само важните събития.

Всяко действие е събитие. Всяко наблюдение също е събитие. Ако моделът отразява всички действия и всички наблюдения, то той ще се претовари с прекалено много информация. Ако моделът се ограничи само до няколко „важни“ събития, тогава това претоварване ще бъде избегнато. По този начин стигаме до идеята за *Event-Driven* моделите.

Недостатък (или може би предимство) на *ED* модела е, че той не описва света напълно, а само частично. По-точно *ED* моделът описва клас от светове (това са световите, изпълняващи определена зависимост).

С какво тази дисертация е различна? Обикновено, когато се разглежда мултиагентна система, се предполага, че светът е даден, а това, което се търси, е стратегия. Тоест светът е част от известните неща в условието на задачата, а стратегията е неизвестното. В тази дисертация ще предполагаме, че светът не е даден, а е това, което се търси.


Обикновено, когато се предполага, че светът е даден, тогава предполагаме, че ни е дадена една релация, която описва света напълно. Тук ще се опитваме да опишем света и ще го описваме частично чрез *ED* модели.

Структура на езика. Описанието на света няма да прилича на хомогенна система, състояща се от един-единствен пласт. По-скоро описанието на света ще има структура, състояща се от много различни пластове. На фигура 1 представяме тази структура като пирамида, където първият пласт е основата.

Първият пласт – това ще са събитията. С тях ще опишем *Event-Driven* моделите. С тези модели ще описваме зависимости. Важно е състоянията на *ED* моделите да не са еднакви. За да се различават състоянията, трябва в поне едно от тях нещо специално да се случва. Това специално нещо ще наречем „особеност“. Множеството от особеностите ще наречем „следа“.

Първата ни идея за следа е това да е нещо постоянно. (Например да имаме едно състояние, където винаги е студено.) Следващата ни идея е подвижната следа, тоест

специалното поведение може да се появи и да изчезне или да се премести. (Например студът да се премести в съседната стая.)



Фигура 1

Следващите пластове в пирамидата – това ще са различни видове зависимости (всички зависимости ще представяме с *ED* модели). Първо ще сложим постоянните зависимости. Това са зависимостите, които се наблюдават през цялото време. В повечето статии се предполага, че всички зависимости са постоянни, но тук ще предположим, че освен тях имаме зависимости, които се наблюдават от време на време. Непостоянните зависимости ще наречем „явления“. Тоест както „следата“ може да е постоянна или подвижна, така и зависимостите могат да бъдат постоянни или „явления“.

Алгоритмите също са непостоянни зависимости (наблюдават се, докато алгоритъмът се изпълнява). Ще представим алгоритъма като последователност от събития. Обикновено алгоритъмът се разглежда като последователност от действия, защото се предполага, че главният герой е този, който го изпълнява. В тази дисертация алгоритмите ще са някакви зависимости и ако някой от агентите действа така, че да запази зависимостта, ще считаме, че агентът изпълнява алгоритъма.

Когато едно явление е свързано с наблюдението на обект, това явление ще наречем „свойство“. По този начин стигаме до абстракция от по-високо ниво. Това е абстракцията за „обект“. Обектите не ги наблюдаваме директно, а ги засичаме благодарение на техните свойства.

Следващата абстракция, до която ще стигнем, това са агентите. Тях също не можем да наблюдаваме директно, но можем да ги засечем благодарение на техните действия. За да опишем света, трябва да опишем агентите, които живеят в него, и да кажем какво знаем за тях. Най-важното е дали са ни приятели и дали с действията си ще се опитват да ни помогнат, или да ни попречат.

Дотук описваме изчислими светове (такива, които могат да се емулират с компютърна програма). Ако вътре в света има неизчислим агент, това ще направи света неизчислим, но има и друг начин да опишем неизчислим свят. Можем да добавим правило, зависещо от това дали съществува някакъв алгоритъм (по-точно съществува ли изпълнение на този алгоритъм). Въпросът дали съществува изпълнение на алгоритъм е неизчислим (*halting problem* – Turing, 1937).

Приноси:


1. *Event-Driven* модел. (Това понятие вече е въведено в Dobrev (2018), но там не е дадена интерпретация на *ED* модела. Именно интерпретацията е това, което дава смисъл на модела, и това, което разграничава адекватните от неадекватните модели.)
2. Показваме, че *Markov decision process (MDP)* е частен случай на *ED* модел и че *ED* моделът е естественото обобщение на *MDP*.
3. *Simple MDP*. Опростяваме *MDP* и получаваме по-прост модел, който описва повече светове.
4. Разширен модел. Това е моделът, при който състоянието знае всичко. Чрез този модел ние ще въведем интерпретация на събитията и на *Event-Driven* моделите. (Разширеният модел е въведен в Dobrev (2019a), но там състоянието знае само какво се е случило и какво ще се случи, но не знае какво е възможно да се случи. Тоест в Dobrev (2019a) състоянието на разширения модел не знае за пропуснатите възможности. В Dobrev (2019a) разширеният модел се нарича „максимален“.)
5. Дефиниция на понятието алгоритъм. Представяме алгоритъма като последователност от събития в произволен свят. Представяме машината на Тюринг като *ED* модел, който се намира в един специален свят, в който имаме безкрайна лента. По този начин показваме, че новата дефиниция обобщава понятието „машина на Тюринг“ и разширява понятието алгоритъм.
6. Език за описание на светове, при който описанието може да се търси автоматично без помощта на човек.

2.3 Играта шах

Кой ще е конкретният свят, който ще използваме за да създадем новия език за описание на светове? Това ще е светът на играта шах.

Първо ще отбележим, че ще искаме светът да е *partially observable*, защото, ако агентът вижда всичко, светът не е интересен. Ако вижда всичко, на агента няма да му е нужна фантазия. Най-важното за агента е да си представи тази част от света, която той не вижда в текущия момент.

За да бъде светът *partially observable*, ще предположим, че агентът не вижда цялото табло, а само едно квадратче от табло (фигура 2). Окоето на агента ще се намира в квадратчето, което вижда в момента, но той ще може да мести окоето си и по този начин ще може да огледа цялото табло. Формално погледнато, няма разлика между това дали виждате цялото табло или само едно квадратче, но можете да местите поглед и да огледате всичко. Няма разлика, ако знаете, че, местейки поглед, оглеждате цялото табло. На практика агентът не знае нищо и той ще трябва да си изгради представата за цялото табло, а това няма да е прост процес и ще изисква фантазия.



Фигура 2

На фигура 2 окото на агента се намира в квадратчето **a2** и агентът може да го мести в четирите посоки. (В този момент не може да го премести наляво, защото е в края на табло и ходът наляво е некоректен.) Освен местенето на окото в четирите посоки, агентът има още две действия и това са „вдигни фигурата, която виждаш“ и „спусни вече вдигнатата фигура в квадратчето, което виждаш“. Тези две действия ще означим с *up* и *down*. С помощта на тези шест действия агентът може да огледа табло и да премести фигура, а това е всичко, което му е нужно, за да играе шах.

2.3.1 Шах с един играч

Ще разгледаме два варианта на играта шах. Ще разгледаме шах с един играч и шах с двама играчи.

Какво означава шах с един играч? Това означава, че играем с белите, обръщаме дъската и играем с черните и т.н.

Първо ще опишем по-простия вариант, когато агентът е сам и играе срещу себе си. Това е по-простият вариант, защото в този свят има само един агент и това е главният герой. По-долу ще разгледаме и по-сложния вариант, при който в света има и втори агент, който е противник на главния герой.

Въпросът е: каква е целта, когато играем сами срещу себе си?

2.3.2 Цел

В повечето статии за ИИ се избира цел, но в тази дисертация няма да фиксираме конкретна цел. Ние искаме само да опишем света, а когато сме разбрали света, бихме могли да си поставим различни цели. Например при играта шах може целта ни да е да спечелим или да загубим. Когато играем сами срещу себе си, може целта ни да се променя. Може когато играем с белите, целта ни да е „да спечелят белите“ и обратното.

Разбирането на света не е пряко свързано с поставянето на конкретна цел. Естественият интелект (човекът) обикновено няма ясно дефинирана цел, но това не му пречи да живее.

Има два въпроса: „Какво става?“ и „Какво да правя?“. Повечето статии за ИИ се опитват директно да отговарят на втория въпрос, без да отговорят на първия. Тоест обикновено директно се търси стратегия, а за да има стратегия, трябва да има цел. В тази

дисертация се търси отговор само на първия въпрос, а вторият въобще не се разглежда. Тоест в тази дисертация не ни е нужна цел.

В повечето статии целта се дефинира чрез *rewards* (целта е да се съберат повече награди). Когато говорим за *Markov decision process (MDP)*, ще предполагаме, че от дефиницията са махнати наградите, защото те са ни нужни само ако ще търсим стратегия, а ние няма да го правим.

2.4 Литературен обзор

Може ли светът на играта шах да бъде описан с помощта на вече известните инструменти за описание на светове? Ще разгледаме известните до момента инструменти за описание на светове и ще покажем, че те не са подходящи.

2.4.1 *Markov decision process*

За описание на светове най-разпространеният инструмент е *Markov decision process (MDP)*. Може ли избраният от нас свят да бъде описан чрез *MDP*? Първо ще отбележим, че ще трябва да използваме *Partially observable MDP (POMDP)*, защото светът, който искаме да опишем, е *Partially observable*.

Разбира се, този свят може да се представи като *POMDP*, но колко състояния ще са нужни? Ще ни трябват толкова състояния, колкото са позициите на шахматната дъска, а това е ужасно много (някъде около 10^{45} според Tromp, 2021). Ще ни трябват дори малко повече състояния, защото състоянието ще трябва да помни освен позицията на дъската и координатите на окото. Тук 64 пъти повече е малко повече, защото при толкова големи числа добавянето на още две нули към числото изглежда незначително увеличение. Тоест числата 10^{45} и 10^{47} ни изглеждат близки.

Ако искаме да опишем подобен *POMDP* като таблица, тогава това описание ще е толкова огромно, че паметта на който компютър няма да е в състояние да го събере. Разбира се, съхранението на описанието е най-малкият проблем. Много по-сериозен проблем е, че ние тази таблица би трябвало да я намерим и да я построим на базата на жизнения си опит, а за толкова голяма таблица ще ни е нужен на практика безкраен жизнен опит.

Тоест идеята да търсим описание на този свят под формата на *POMDP* е обречена на неуспех.

2.4.2 *Situation Calculus*

Първото предложение за език за описание на светове е направено от Raymond Reiter и това е неговият *Situation Calculus* описан в Reiter (2001).

Светът на играта шах може да се представи чрез формализма, предложен от Raymond Reiter, но има два проблема (малък проблем и голям проблем).

Първият (малкият) проблем е, че Reiter представя състоянието на света, получено след действие чрез функционален символ. Тоест той предполага, че следващото състояние е еднозначно определено. Това предположение не е проблем за детерминистични светове, какъвто е светът на играта шах, но би било проблем за игри със зарове. Разбира се, това е малък проблем, защото можем да предполагаме, че следващото състояние е определено, но ние не знаем точно кое е то. (Тоест можем да предположим, че има съдба, която еднозначно определя бъдещето, макар че това не ни помага да предскажем какво ще се случи.)

Един опит за решаването на първия (малкия) проблем е направен в параграф 3.2. на Boutilier, Reiter and Price (2001). Там всяка стъпка е заменена с две стъпки (*plies*). Вместо една стъпка на агента имаме *ply* на агента и *ply* на *nature*. Идеята е, че стъпката на агента е недетерминирана, защото светът (природата) може да отговори по много различни начини, но ако разделим действието на агента от отговора на природата, тогава резултатът от всяка стъпка (*ply*) е детерминиран. Ние използваме по същество същата идея, когато създаваме *Simple MDP*.

Вторият (големият) проблем на *Situation Calculus* е, че Reiter негласно предполага, че има човек (програмист), който е разбрал устройството на света и който ще го опише чрез формули от първи ред. Всички ние искаме да стигнем до описание на света чрез формули от първи ред, но целта е това описание да може да бъде намерено автоматично без намесата на човек. Вярно е, че в настоящата дисертация се дава описание на играта шах, което е направено от човек, но целта ни е това описание да се търси автоматично и даденото тук описание е такова, което би могло да се търси и намери автоматично.

2.5 Жизнен опит

Задачата е да опишем света на базата на жизнения си опит. Тоест търсим модел, обясняващ най-добре това, което се е случило до момента. Затова първият въпрос, който ще си зададем, е: „Какво е жизнен опит?“.

Обикновено се предполага, че имаме само един живот и жизненият опит е това, което се е случило до момента в този живот. Тук ще предположим, че имаме повече от един живот и че жизненият опит е това, което се е случило в текущия живот и във всички досега изживени животи. Дори ще предполагаме, че може да имаме повече от един текущ живот.

Защо правим това предположение? Ако мислим от гледната точка на индивида, той има само един живот, но ако погледнем нещата от гледната точка на популацията, то тогава животите са много. В нашия случай имаме изкуствен агент, който живее в изкуствен свят. Бихме могли да пуснем агента многократно да живее в света и да получим много животи, на базата на които да събираме наблюдения и да търсим зависимости. Бихме могли дори да пуснем много агенти, които едновременно да живеят в света. Тогава ще имаме много текущи животи едновременно.

Дефиниция: „Жизнен опит“ ще наричаме крайна последователност от животи.

Следващият въпрос е: „Какво е живот?“.

2.5.1 Живот

Животът ще бъде крайна последователност от действия и наблюдения. Това е, което виждаме, но дали в живота има и неща, които не виждаме?

Нека си представим два живота. В първия ние минаваме покрай гърне с жълтици, но не го отваряме и продължаваме нататък. Във втория живот ние минаваме покрай празно гърне, което не отваряме, и пак продължаваме нататък. Двата живота като действия и наблюдения са абсолютно идентични, но все пак те са различни, защото в първия ние сме имали шанса да намерим жълтиците, а във втория не сме имали този шанс.

Затова в описанието на живота ще сложим две неща. Първото е това, което сме видели (последователността от действия и наблюдения). Тази последователност ще наречем „следата на живота“.

Забележка: В тази дисертация говорим за „следата на живота“ и за „следата на *ED* модела“. Това са две различни понятия.

Второто, което ще определи живота, е какво е било възможно да се случи (без значение дали действително се е случило). Възможното минало и възможното бъдеще се описват от състоянието на света. Важно е какво е било състоянието във всеки момент. Затова към описанието на живота ще добавим последователността от състояния, през които е преминал светът. Ще наречем тази последователност „гръбнака на живота“.

Следата и гръбнакът описват живота от гледна точка на света. Ако погледнем на света от гледната точка на агента, животът ще се опише чрез следата и предположенията, които може да направи агентът във всеки един момент. Например в един момент можем да предположим, че след две стъпки ще видим определено наблюдение. (Моментът на предположението е моментът, в който можем да го направим, а не моментът, за който се отнася.)

За всяко предположение са важни две неща. Първото са предпоставките, които трябва да са налице в момента, когато правим предположението. Второто е правилото (евристиката), на базата на която предположението ще бъде направено. Ще предполагаме, че евристиката е получена от целия ни жизнен опит (включително бъдещия жизнен опит). Тоест, когато жизненият опит се увеличава, се променят евристиките и оттам се променят и предположенията (дори и вече направените предположения). Например в един момент разбираме, че шумът от изстрел е свързан с опасност. Тогава преразглеждаме миналото и установяваме, че когато сме чували изстрел, е било опасно.

2.5.2 Евристика

Казахме, че в живота има неща, които ние не виждаме, но които е важно да се опитаме да предскажем. Например: „Има ли жълтици в гърнето?“. Ще се опитаме да предскажем това чрез нашето шесто чувство или чрез някакви евристики, които сме намерили от нашия жизнен опит чрез събиране на статистика. Пример за подобна евристика е: „Ако гърнето изглежда старо, то то е пълно с жълтици“. Разбира се, евристиката има някакъв коефициент на достоверност. Нека този коефициент да е само 2%. Дори и при този нисък коефициент на достоверност си струва да отворим гърнето и да проверим за жълтици, когато то изглежда старо.

Евристиката ще се състои от предпоставка, заключение и коефициент на достоверност. Ще предполагаме, че заключението е атомарна формула, а предпоставката е конюнкция от атомарни формули. (По-долу ще кажем какво е атомарна формула.)

Дефиниция: Евристиката ще бъде импликация с коефициент на достоверност:

$$A_1 \& A_2 \& \dots \& A_n \Rightarrow A_0 \text{ (процент)}$$

Ето един пример за евристика:

$$Ob(t-1)=o_1 \& Act(t)=a \Rightarrow Ob(t+1)=o_2 \text{ (10\%)}$$

Тук $Ob(t)=o$ означава, че наблюдението в момента t е o , а $Act(t)=a$ означава, че действието в момента t е a . (При записва използваме равенство, защото наблюдението и действието еднозначно зависят от t .)

Събитието $Ob(t)$ има смисъл само в четните моменти, а $Act(t)$ има смисъл само в нечетните моменти, защото редуваме действие–наблюдение. Евристиката е валидна за всяко t . Затова ще предполагаме, че предпоставката е известна в момента t и че това е първият момент, в който предпоставката става известна. (Това можем да го постигнем като заменим t с $t+i$ за някое i .)

Тук заключението е свързано с бъдещо видимо събитие (няма смисъл да предсказваме минало видимо събитие). Заключението би могло да бъде свързано и с невидимо събитие (минало или бъдеще). Например:

$$Ob(t)=o_1 \Rightarrow PossNext(o_2, t-2) \text{ (някакъв процент)}$$

Тук невидимото събитие $PossNext(o, t)$ означава, че е възможно следващото наблюдение да бъде o , т.е. възможно е $Ob(t+2)=o$. (При записа не използваме равенство, защото може да имаме повече от едно възможно следващо наблюдение, а равенството предполага, че това наблюдение е единствено.)

При $o_1=o_2$ горната евристика ще е безсмислена, защото ще е тавтологично вярна, но при $o_1 \neq o_2$ ще има смисъл за всеки минал и бъдещ момент.

На евристиките гледаме като на правила, които са валидни винаги, но бихме могли да предположим, че едно правило е валидно само понякога. Тогава това непостоянно правило ще дефинира едно невидимо събитие. Това събитие ще е истина, когато правилото е валидно, и лъжа, когато не е. Нека разгледаме правилото:

$$\emptyset \Rightarrow Ob(t+2) \neq o$$

Тук предпоставката е празното множество, тоест без предпоставка или винаги. Това правило ни казва, че следващото наблюдение не може да бъде o . Това понякога е вярно, а понякога не е, но ние не виждаме дали е вярно (освен в случая, когато следващото наблюдение е o , но в общия случай не виждаме). Тоест това е едно невидимо събитие и неговото отрицание е точно $PossNext(o, t)$.

2.5.3 Атомарна формула

Агентът не може да наблюдава всички събития и ще трябва да се ограничи до краен брой. На всяко наблюдавано събитие агентът ще даде име и тези събития ще наречем атомарни формули.

Дефиниция: Атомарна формула е събитие, на което сме дали име.

Например $Ob(t)=o$ е атомарна формула. (По-точно това са много атомарни формули, по една за всяко o .)

Когато наблюдаваме едно събитие, практически ние наблюдаваме и неговото отрицание. Затова отрицанието на атомарна формула също е атомарна формула.

Конюнкция от атомарни формули също може да бъде атомарна формула, ако сме решили да я наблюдаваме и сме ѝ дали име. Разбира се, тези конюнкции са безбройно много и не можем да ги наблюдаваме всичките.

От събитието $A(t)$ ние можем да направим безброй събития $A(t+i)$, които ще са същото събитие, но шифтвано във времето. Безсмислено е да наблюдаваме всичките тези събития, защото те са почти еднакви. Затова ще наблюдаваме само едно от тях. Например при конюнкция от атомарни формули ще считаме, че наблюдаваме това събитие в момента, който е максимумът от моментите на атомарните формули, участващи в конюнкцията.

При повечето случаи няма значение точно в кой момент се случва наблюдаваното събитие, но има и изключения. Например при *ED* моделите е важно кога точно се случва всяко от наблюдаваните събития (дали се случва няколко стъпки по-рано, или няколко стъпки по-късно).

2.5.4 Моментно събитие

Дефиниция: Моментно събитие е такова, което зависи само от един момент.

Нека моментът е t . Тогава моментно видимо събитие е такова, което зависи само от едно наблюдение или само от едно действие – от $Ob(t)$ или от $Act(t)$. Моментно невидимо събитие е такова, което зависи само от едно от състоянията на света (s_t).

Конюнкция от моментни събития може да е моментно събитие, ако всичките атоми на конюнкцията са моментни събития и се отнасят за един и същи момент.

Видимите моментни събития са крайно много, а невидимите са толкова, колкото са подмножествата от състояния на света (крайно или континуум).

Атомарната формула може да е моментно събитие, а може и да не е.

2.5.5 Предположение

В конкретни моменти от времето агентът ще прилага евристиките, за да получи някакви предположения. Всяко предположение ще се състои от заключение и от коефициент на достоверност. Заключение ще бъде атомарна формула и тя ще се отнася към конкретен момент от времето t (този момент може да е в миналото или в бъдещето). Тоест евристиката беше за всяко t , а предположението е за едно конкретно t .

Дефиниция: Предположението има вида:

$$A(t) \text{ (процент)}$$

Множеството на всички предположения (приложения на евристики) ще означим с *Guesses*.

Нека имаме още една евристика: „Ако гърнето е пълно с жълтици, то можем да си купим самолет“. Нека коефициентът на достоверност на тази евристика е 50%. Тогава в момент, когато виждаме гърне, което изглежда старо, прилагаме първата евристика и получаваме „гърнето е пълно с жълтици“ (с достоверност 2%). Оттам получаваме, че можем да си купим самолет (с достоверност 1%).

Важното, което се вижда от този пример, е, че можем да прилагаме евристиките каскадно и че в предпоставките на евристиката може да имаме невидимо събитие. Каскадното прилагане на две евристики може да се разглежда като една нова евристика, но за директното намиране на тази нова евристика ще трябва твърде много жизнен опит. По-добре е да намираме по-прости евристики и да ги комбинираме, като получаваме по-сложни. Можем да намерим много евристики за това, че в гърнето има жълтици, и чрез каскадното прилагане да заключим, че във всичките тези случаи можем да си купим самолет. Ако не използваме каскадното прилагане, тогава за всеки отделен случай ще трябва да съберем отделна статистика, която да докаже, че в този конкретен случай можем да си купим самолет.

2.5.6 Дефиниция на живот

Ще разгледаме живота като игра между двама играчи. Първият играч ще бъде агентът (главният герой), а вторият играч ще наречем „природа“ и това ще бъде самият свят. Агентът „природа“ не прави каквото си иска. Той действа по някакви правила, макар че може да има известна свободна воля. По-нататък ще се опитаме да си обясним света и ще заменим природата с група агенти. Тази група ще се състои от нула, един, двама или повече агенти. Когато това е празната група, ще казваме, че в света няма други агенти освен главния герой.

Животът ще се състои от две неща: следа и гръбнак.

Дефиниция: Живот:

$a_1, o_2, a_3, o_4, \dots, a_{k-1}, o_k$, където $a_i \in \Sigma, o_i \in \Omega$.

$u_0, w_1, u_2, w_3, \dots, w_{k-1}, u_k$, където $u_i \in U, w_i \in W$.

Тук Σ са възможните действия, Ω са възможните наблюдения на агента, U са състоянията на света, когато агентът е на ход, а W са състоянията на света, когато природата е на ход. С k сме означили дължината на живота (ако животът е L , тогава дължината му е $|L|$).

Ако напишем следата и гръбнака на един ред, това ще изглежда така:

$u_0, a_1, w_1, o_2, u_2, a_3, w_3, \dots, a_{k-1}, w_{k-1}, o_k, u_k$

От гледна точка на света, животът е следа и гръбнак, от гледна точка на агента – животът е следа и предположения, от гледна точка на двамата – животът е живот с предположения.

Дефиниция: Живот с предположения:

- следа,
- гръбнак,
- предположения на агента (приложения на евристики):

$g_0, g_1, g_2, \dots, g_k$, където $g_i \subseteq \text{Guesses}$.

Множеството g_i се състои от предположенията, които агентът може да направи в момента i (не по-рано, а точно в този момент). Всички предположения, валидни в момента t , са:

$$G_t = \bigcup_{i \leq t} g_i$$

Множеството G_t от предположенията може да е противоречиво. За някое j можем да предположим едновременно $A(j)$ и $\neg A(j)$ (евентуално с различна достоверност). Предположенията $A(j)$ и $\neg A(j)$ може да се появят в един момент (в едно g_i), а може да се появят в два различни момента.

Агентът мисли само в четните моменти, защото тогава той е на ход. Ако t е четен момент, тогава агентът не може да избере предположенията g_t , защото те се определят от миналото, но той може да избере предположенията g_{t+1} , защото те се определят от миналото и от неговото следващо действие. (Тоест агентът ще пробяга възможните действия и ще избере това, което би му дало най-доброто g_{t+1} .)

2.6 Event-Driven модели

Преди още да сме казали какво е събитие, ще кажем какво е *Event-Driven* модел. Грубо казано, *ED* моделът е един ориентиран граф, в който върховете отговарят на състояния на света, а стрелките са етикирани със събития. Предполагаме, че светът си седи в едно от състоянията, докато не се случи някое от наблюдаваните събития. Тогава светът преминава в друго състояние, като преходът става по стрелка, етикирана със събитието, което се е случило.

Важно нещо за *ED* модела – това са особеностите. Особеност ще наричаме, когато в едно състояние едно събитие се случва с вероятност, различна от очакваната (от средната). Особеностите ще ни помагат, от една страна, да разберем в кое състояние на света сме, а,

от друга страна, да предсказваме какво ще се случи и какво се е случило. Множество от особености ще наричаме следа.

Стрелките в *ED* модела, както и особеностите ще си имат вероятност. Вместо точна вероятност ние ще използваме вероятностни интервали. Първо ще кажем защо предпочитаме да използваме вероятностни интервали. Второ ще кажем защо правим разлика между невъзможно и възможно, но невероятно. Трето, ще въведем статистиката, която ще даде смисъл на тези вероятности. Чак след това ще дадем дефиниция на *ED* моделите.

2.6.1 Вероятностен интервал

Когато играете баскетбол и се опитвате да вкарате кош, каква е вероятността да уцелите? Можем да направим сто опита и да изчислим тази вероятност чрез статистиката. Може да има и други фактори, които да влияят на тази вероятност. Например какво е осветлението и дали сте уморен. Можем да направим по-сложен модел, който да включва и тези фактори, но въпреки това винаги ще останат фактори, които не сме успели да включим. Тези неизвестни фактори ще ни дадат някакво отклонение във вероятността и тя няма да бъде точна стойност, а ще бъде някакъв интервал.

Най-важният от тези допълнителни фактори е нашата свободна воля. Когато стреляме, много важно е дали искаме да вкараме, или не искаме. Да допуснем, че когато не искаме, ние вкарваме по погрешка с вероятност a , а когато искаме, вкарваме с вероятност b (тогава вкарваме нарочно). Тоест, когато стреляме по коша, ние ще вкараме с вероятност, която е в интервала $[a, b]$.

2.6.2 Възможно, но невероятно

Дали има разлика между невъзможно и невероятно? Ще правим разлика между липсваща стрелка и стрелка с вероятност нула (т.е. вероятностният интервал $[0, 0]$).

Вероятността на едно събитие може да клони към нула. Например ако събитието се случва веднъж в първите десет, веднъж в следващите сто и т.н. Тогава събитието е възможно, но неговата вероятност е нула (или клони към нула).

Когато разглеждаме действията на света (наблюденията на агента), тогава разликата между невъзможно и невероятно е малка, но когато разглеждаме действията на агента, тогава разликата е много съществена, защото това е начинът, по който дефинираме понятието „некоректен ход“.

Когато стрелките са по действия и една стрелка липсва, ще предполагаем, че действието е некоректно (некоректен ход). Това ще е отделно събитие, което ще наречем „полувидимо“. Когато има стрелка с вероятност нула, това ще означава, че действието е коректно, но по някаква причина нашият агент това действие никога не го извършва (или почти никога).

2.6.3 Статистика

Основният инструмент, който агентът използва, за да разбере света, е статистиката. Тук ще разгледаме два вида статистика. Първата е статистиката на агента и тя е на базата само на действията и наблюденията. Това е реалната статистика, с която агентът разполага.

Ще разгледаме и втори вид статистика. Ще я наречем „статистиката на света“. Тази статистика, освен действията и наблюденията, ще отчита още и състоянията на света. Статистиката на света можем да си я мислим като статистика, направена от някакъв суперагент, който е в състояние да види кое е състоянието на света. Разбира се, такъв

суперагент не съществува. Предполагаме, че светът знае кое е състоянието, в което се намира. Затова светът би могъл да направи такава статистика, но той няма да я сподели с агента.

Тоест статистиката на света е нещо абстрактно, което агентът не може да види, но ние ще използваме тази статистика, за да дефинираме и да дадем смисъл на някои от въведените понятия. Например каква е вероятността по една стрелка да се премине от едно състояние в друго? Нека предположим, че вероятностите са фиксирани и ще определим тези фиксирани вероятности чрез статистиката на света. Ще направим N стъпки и за всяко състояние и за всяка стрелка ще преброим колко пъти сме минали през тях (колко пъти сме влезли в състоянието, без значение колко стъпки сме били в него). Ако през една стрелка сме минали k пъти, а през състоянието, от което тя излиза, сме минали m пъти, тогава вероятността на стрелката ще бъде приблизително k/m . Разбира се, при малко N грешката ще е голяма, но при голямо N може да приемем, че вероятността е точно k/m . Тоест вероятността ще е границата на k/m , когато N клони към безкрайност.

Така използвахме статистиката на света, за да дадем смисъл на вероятността на стрелките. Можем ли да я използваме, за да дефинираме вероятностните интервали? Това ще е малко по-трудно. Нека отново сме направили N стъпки. Нека n е най-голямото цяло число, за което $n^2 \leq N$. Ще разделим интервала N на n интервала, всеки от които с не по-малко от n стъпки. За всеки от тези n интервала ще направим статистика и ще получим някаква вероятност p_i . Вероятностният интервал на стрелката ще бъде приблизително $[min(p_i), max(p_i)]$. Когато N клони към безкрайност, би трябвало да получим точната стойност, но все пак, за да бъде това вярно, ще трябва да направим едно предположение.

Ще предположим, че светът и агентът променят фиксираната си стратегия, но го правят рядко и оттам рядко се променя фиксираната стратегия на ED модела (по-долу казваме какво е фиксирана стратегия). Когато светът и агентът изпълняват фиксирана стратегия, тогава вероятността на всички стрелки в ED модела също ще е фиксирана. Ако светът и агентът сменят стратегията си прекалено често, тогава този метод за статистика няма да даде нужния резултат (т.е. ще даде по-тесни интервали от действителните).

2.6.4 Дефиниция на ED модел

Дефиниция: *Event-Driven* моделът ще се състои от три части.

Топология:

- S – множество от състоянията на модела (крайно или изброимо).
- E – множество от наблюдаваните събития (малък брой събития).
- $R \subseteq S \times E \times S$ – релация между състоянията, етикетирана с наблюдаваните събития.
- Правило за разрешаване на колизиите.

Частична следа:

- $Trace \subseteq Distinctions$ – множество от особености.

Вероятности:

- *Probability*: $R \rightarrow [0, 1] \times [0, 1]$ – функция, която на всяка стрелка връща вероятностен интервал.
- *Back Probability*: Същото като *Probability*, но вероятностите са за миналото (когато вървим обратно на стрелките).

Дефиниция: „Особеност“ ще бъде наредена тройка, състояща се от състояние, събитие и вероятност. Вероятността ще бъде вероятностен интервал или константата *never*. Вероятността трябва да бъде различна от средната вероятност на събитието (очакваната вероятност). Множеството на всички такива наредени тройки ще бъде *Distinctions*.

Ще предполагаме, че една стрелка липсва точно тогава, когато в следата има особеност, че в това състояние това събитие не може да се случи. Тоест:

$$\forall s_1 \in S \forall e \in E (\neg \exists s_2 \in S \langle s_1, e, s_2 \rangle \in R \Leftrightarrow \langle s_1, e, \text{never} \rangle \in \text{Trace})$$

Наблюдаваните събития са тези, които са върху стрелките на модела. Събитията, които участват в следата, ще наречем „допълнителни събития“. Наблюдаваните и допълнителните събития може да имат сечение, а може и да нямат.

Наричаме *Trace* „частична“, защото предполагаме, че съдържа само част от особеностите на модела. Ако предположим, че всички особености на модела са вътре, тогава ще говорим за пълна следа. (Ако моделът има повече от една интерпретация, тогава трябва да говорим за следата на интерпретацията вместо за следата на модела.)

Правилото за разрешаване на колизиите ни казва кое е следващото състояние на *ED* модела, ако събитията *a* и *b* от *E* се случат едновременно.

Правилото може да е детерминистично:

1. Събитието *a* има приоритет пред събитието *b* и в този случай се изпълнява *a*.
2. В този случай се изпълняват последователно и двете събития, като първо се изпълнява *a*, а после *b*.
3. Има отделна стрелка, която ни казва къде да отидем, когато се случи *a* & *b*.

Правилото може да бъде и недетерминистично:

4. Избираме събитието *a* с вероятност *p* (или с вероятност в интервала $[p_1, p_2]$).

2.6.5 Интерпретация

Кога *ED* моделът е модел на света? За да отговорим на този въпрос, ще дефинираме интерпретация и характеристика. При тази дефиниция ще използваме статистиката на света. Тоест ще използваме информацията за това кое е състоянието на света, а това е нещо, което агентът не знае.

За да бъде *ED* моделът модел на света, трябва да има връзка между живота и състоянието му. Тази връзка ще наричаме „интерпретация“ и тя ще ни даде за всеки момент от живота в кое състояние се намира *ED* моделът (ще ни го даде точно или приблизително). Тоест интерпретацията е функция, която за всеки момент от живота ни дава състояние на *ED* модела (или множество от състояния, или *belief*).

Интерпретацията може да не е единствена, но ако разширим частичната следа, тя ще стане единствена. (Можем да я разширим малко или да я разширим до пълната следа.)

Разбира се, интерпретацията не е произволна функция, а такава, която е съгласувана с *ED* модела. Когато в няколко последователни момента никое от наблюдаваните събития не се случва, тогава интерпретацията трябва да връща едно и също състояние за тези моменти. Когато се случи някое от наблюдаваните събития, тогава в следващия момент интерпретацията трябва да върне ново състояние, но трябва в *ED* модела да има стрелка по това събитие от предишното състояние към новото.

Ще разгледаме няколко вида интерпретации.

1. Проста интерпретация. Това е функция, която за всяко състояние на света ни връща състояние на *ED* модела.

2. Еднозначна интерпретация. Това е функция, която за всеки момент от всеки безкраен живот ни връща състояние на *ED* модела. Всяка проста интерпретация е однозначна, но не и обратното.

3. Интерпретация чрез множества. Същото като еднозначната интерпретация, но функцията връща множество от състояния на *ED* модела вместо едно състояние.

4. Интерпретация чрез *beliefs*. Същото като интерпретация чрез множества, но функцията връща *belief* от състояния на *ED* модела (тоест множество с вероятности).

За да опростим изложението, няма да разглеждаме случаите 3 и 4. Тоест, когато говорим за интерпретация, ще имаме предвид однозначна интерпретация.

Функциите над моментите в живота ще наричаме „многозначни събития“. Обикновеното събитие е двузначно, то или се случва, или не се случва. Ако едно събитие е *n*-значно, ще го представим като *n* двузначни събития, които не се пресичат (не могат да се случат едновременно). Тоест интерпретацията е многозначно събитие. Ще предполагаме, че интерпретацията е дефинирана при всеки безкраен живот. Когато животът е краен, може да имаме проблем с дефиницията на някое събитие. Ако не ни достига информация за миналото или за бъдещето на живота, стойността на събитието може да е „не знам“. Затова приемаме, че интерпретациите са дефинирани върху безкрайните животи.

Дефиниция: Безкраен живот ще се състои от безкраен гръбнак и от безкрайна следа (безкрайността е в двете посоки):

$$\begin{aligned} & \dots, o_{-2}, a_{-1}, o_0, a_1, o_2, a_3, \dots \\ & \dots, u_{-2}, w_{-1}, u_0, w_1, u_2, w_3, \dots \end{aligned}$$

На един ред ще изглежда така:

$$\dots, o_{-2}, u_{-2}, a_{-1}, w_{-1}, o_0, u_0, a_1, w_1, o_2, u_2, a_3, w_3, \dots$$

За интерпретацията ще кажем, че е видима, ако тя се описва от видими събития. Видимата интерпретация е единствена.

Приемаме, че *ED* моделът се описва от топологията и от частичната следа. По това описание търсим интерпретация (една от възможните). После от интерпретацията можем да получим пълната следа и вероятностите.

2.6.6 Характеристика

За да бъде *ED* моделът модел на света, той трябва да има интерпретация, но това не е достатъчно. Тази интерпретация трябва да има смислена характеристика.

Всяко събитие има характеристика и това е размито множество от състоянията на света, в които събитието се случва.

Дефиниция: Характеристика на събитие е функция, която на всяко състояние на света съпоставя вероятността това събитие да се случи, когато светът е в това състояние.

Разликата между *belief* и характеристика е, че *belief* описва едно състояние, докато характеристиката описва множество от състояния. Сумата от вероятностите на *belief* е единица, а при характеристиката тази сума е между нула и безкрайност.

Интерпретацията е многозначно събитие, тоест тя се състои от много събития, всяко от които си има характеристика. Характеристика на интерпретацията ще бъде множеството от всички тези характеристики. За да бъде характеристиката на интерпретацията смислена, трябва тези характеристики да не са еднакви.

Забележка: Ще предполагаме, че всичко, което състоянията на света „помнят“ и „знаят“, е съществено. (По-долу ще кажем, че предполагаме, че моделът на света е минимален.) Тоест, ако характеристиките на две събития са различни, то има нещо съществено, което ги различава.

Забележка: Когато характеристиката на *ED* модела не е смислена, тогава пълната следа е празното множество. Тоест нищо интересно не се случва.

Най-хубав е случаят, когато характеристиките не са размити множества, а са обикновени множества. Тогава имаме проста интерпретация и смислена характеристика.

Важно е дали *ED* моделът „помни“ съществени неща. Ако помни само съществени неща, тогава имаме проста интерпретация. Ако моделът помни само несъществени неща, тогава нямаме интерпретация или имаме, но характеристиката ѝ не е смислена.


Да вземем като пример *Fully observable MDP (FOMDP)*. Този *ED* модел „помни“ кое е последното наблюдение. Да допуснем, че в нашия свят това е нещо несъществено. Интерпретацията на *FOMDP* е видима, но характеристиката на тази единствена интерпретация ще е безсмислена, защото каквото и да е последното наблюдение, очакваното състояние на света ще е едно и също (защото предположихме, че в нашия свят това е безсмислена информация). Ако в нашия свят последното наблюдение беше съществена информация, тогава характеристиката на интерпретацията на *FOMDP* щеше да е смислена.

Нека сега да предположим, че последното наблюдение се помни от състоянието на света (тоест това е съществена информация и всяка буква от тази информация е съществена). Щом светът „помни“ кое е последното наблюдение, можем да разделим състоянията по това наблюдение и това ще е релацията на еквивалентност. Тогава *FOMDP* има проста интерпретация и тя съвпада с видимата.

Забележка: Това, което описахме по-горе, се отнася за постоянните зависимости с постоянна следа. Зависимостта може да е временна (явление) и тогава интерпретацията няма да е върху целия живот, а ще бъде върху части от живота. (Явленията не се случват постоянно, а от време на време). Подвижната следа също усложнява модела.

2.6.7 Примери

Нека вземем едно събитие *a* и *ED* модела, който помни дали това събитие се е случило четен или нечетен брой пъти (фигура 3).



Фигура 3

Нека предположим, че в нашия свят има значение дали събитието се е случило четен или нечетен брой пъти. Тогава всяко състояние на света „знае“ това и можем да

разделим състоянията на две множества (такива, в които a се е случило четен брой пъти, и останалите). Тогава имаме две прости интерпретации на ED модела. Можем да съпоставим на s_1 множеството от състояния, в които a се е случило четен брой пъти, а можем да го съпоставим на s_2 . Всяка от тези две интерпретации ни дава следа. Можем да вземем пълната следа, но за да различим двете интерпретации, е достатъчно да вземем произволна непразна част от пълната следа. Вероятностите по стрелките също се определят от интерпретацията, но в случая те са единица навсякъде.

Нека сега предположим, че в нашия свят няма никакво значение дали събитието a се е случило четен или нечетен брой пъти. При това предположение ED моделът от фигура 3 помни само несъществени неща. В този случай моделът няма да има интерпретация, защото тази интерпретация трябва за нещо да се хване. Състоянието на света не знае кое е състоянието на модела (s_1 или s_2), а миналото и бъдещето също не ни дават тази информация. Тоест няма функция, която еднозначно да определя s_1 или s_2 .

Ако се откажем от изискването моделът на света да помни само съществени неща, тогава бихме могли да получим нов модел, в който ще имаме интерпретация, но тази интерпретация нищо няма да ни даде (няма да ни даде следа). Нека да разширим модела на света, като добавим тази несъществена информация (дали a се е случило четен брой пъти). Ще заменим всяко състояние s със състоянията $\langle s, even \rangle$ и $\langle s, odd \rangle$. Ако състоянието s „помни“, че a се е случило четен брой пъти, тогава състоянието $\langle s, even \rangle$ ще е достижимо, а състоянието $\langle s, odd \rangle$ ще е недостижимо (все едно, че го няма). Щом никое състояние не помни този факт, тогава всичките тези нови състояния ще са достижими. Тогава на s_1 ще съответстват всички състояния $\langle s, even \rangle$ или всички $\langle s, odd \rangle$. И в двата случая няма да имаме никаква следа, защото вероятността за всяко събитие ще бъде средната вероятност.

Например в нашия свят имаме събитието „нов ден“. Това е важно събитие, но няма никакво значение дали денят е четен или нечетен. От друга страна, е много важно кой е денят по модул седем, защото това са дните от седмицата. Състоянието на нашия свят „помни“ кой е денят по модул седем. Получаваме ED модел със седем състояния, който има следа. Следата е, че в неделя не се работи. Благодарение на тази следа ние може да синхронизираме всеки достатъчно дълъг живот и да кажем за всеки момент кой ден от седмицата е (кое е състоянието в ED модела). Този ED модел има седем възможни интерпретации, но благодарение на частичната следа „в неделя не се работи“ ние фиксираме една от тези възможни интерпретации.

Друг пример, при който моделът има повече от една интерпретация: да вземем ED модел, в който имаме недетерминиран преход към състоянията s_1 и s_2 . Нека множеството от състоянията на света, които отговарят на s_1 и s_2 , да разделим по различни признаци надве. Може да го разделим на „сини“ и „зелени“ или на „големи“ и „малки“. На всяко едно такова разделяне ще отговаря проста интерпретация. Тези интерпретации може да са много (ако множеството е изброимо, разделянията ще са континуум). Разбира се, колкото повече са особеностите в частичната следа, толкова по-малко са възможните интерпретации, а при пълната следа ще имаме само една възможна интерпретация.

2.7 Събития

Ще разгледаме два вида събития: релевантни и нерелевантни. Релевантните събития ще разделим на три: видими, невидими и полувидими.

2.7.1 Видими събития

Това ще са събитията, които зависят само от следата на живота (действията и наблюденията). Зависят от това, което сме видели, и това, което ще видим.

Забележка: Защо считаме, че събитието може да зависи от бъдещето? Защото бъдещето в един следващ момент ще стане минало и защото бъдещето може да се предскаже. Тоест видимото събитие в по-късен момент ще се види, а чрез предположенията може да се предскаже с известна степен на достоверност още преди да сме го видели. Бъдещето е неизвестно от гледна точка на текущия момент, но спрямо друг момент то може вече да е известно. Например, спрямо края на живота, това бъдеще вече е част от миналото и е известно.

Нека имаме множеството All от всички безкрайни редици от действия и наблюдения:

$$\dots, a_{t-3}, o_{t-2}, a_{t-1}, o_t, a_{t+1}, o_{t+2}, a_{t+3}, \dots$$

Тези редици са безкрайни и в двете посоки (към миналото и към бъдещето). Тук е важно кой е текущият момент „нула“. Тоест безкрайните редици можем да ги приемем за функции: $\mathbb{Z} \rightarrow \Sigma \cup \Omega$.

Дефиниция: Всяко подмножество на All ще наричаме „видимо събитие“.

Тоест за всяка безкрайна редица от действия и наблюдения и за всеки конкретен момент t ние можем да кажем дали събитието се случва, или не се случва.

При тази дефиниция видимите събития станаха прекалено много. Елементите на All са континуум много, което значи, че видимите събития са две на степен континуум.

Ние не разполагаме с безкрайна редица от действия и наблюдения, а имаме само един краен откъс (имаме следата на един конкретен живот). Ще искаме видимите събития да се определят само от този краен откъс. Тогава видимото събитие ще има три възможни стойности. То ще може да е истина, да е лъжа или да е „не знам“.

Дефиниция: Видимото събитие върху откъс:

1. ще е истина, ако както и да продължим откъса до безкрайна редица, се получава редица, за която събитието е истина;
2. ще е лъжа, ако както и да продължим откъса, се получава редица, за която събитието е лъжа;
3. ще е „не знам“ в противен случай.

Ограничавайки видимите събития до откъси, ние силно намалихме техния брой. От две на степен континуум, те станаха континуум много. Кой събития отпаднаха? Например: „Събитието A ще се случи безкраен брой пъти“. Ако ограничим това до краен откъс, то винаги ще даде „не знам“, защото можем да продължим редицата и по двата начина. Разбира се, такива събития не са интересни, защото нас ни интересуват само събития, които можем да разберем в даден момент.

Няма да разглеждаме всички видими събития, а само изчислимите, и то само малка част от тях. Най-важните видими събития са атомарните: $Ob(t)$ и $Act(t)$. Съставните събития, направени от видими събития, също ще са видими събития.

2.7.2 Съставни събития

От атомарните събития можем да правим съставни събития. Конюнкцията на атомарни събития е съставно събитие.

Ако искаме да дадем име на една конюнкция и да я превърнем в атомарна формула, ще въведем съкращаващ символ, който ще бъде името на конюнкцията. (Няма да наблюдаваме дизюнкция, но можем да наблюдаваме конюнкцията от отрицанията, а това е същото.) За всяко съставно събитие можем да въведем съкращаващ символ и да започнем да го наблюдаваме.

Съкращаващите символи за конюнкция ще въведем със специални евристики с коефициент на достоверност 100%. Евристиките ще имат вида:

$$A_1(t-i_1) \& A_2(t-i_2) \& \dots \& A_n(t) \Rightarrow Abbreviation(t) \text{ (100\%)}, i_j \geq 0, i_n = 0.$$

За отрицанията ще добавим още n евристики:

$$\neg A_j(t-i_j) \Rightarrow \neg Abbreviation(t) \text{ (100\%)}$$

Тоест конюнкцията на атомарни събития ще стане атомарно събитие, когато определим съкращаващ символ, означаващ тази конюнкция.

Обикновено евристиките са получени чрез статистика и имат коефициент на достоверност, по-малък от 100%. Затова ще приемем, че въведените тук евристики са добавени служебно.

Друго съставно събитие е „ A ще се случи преди B “. Ще запишем това събитие така: *exist A after t before B in our case*. Това събитие е видимо, когато A и B са видими. Ако в един безкраен живот събитията A и B не се случват след t , тогава събитието ще е лъжа.

2.7.3 Невидими събития

Тук ще говорим за моментните невидими събития. Разбира се, от тях можем да направим и други невидими събития (например чрез конюнкция).

Моментно невидимо събитие (*ISME*) ще бъде такова, което отразява възможното минало и възможното бъдеще в един конкретен момент t . То ще зависи само от едно състояние на света. Интерпретация на *ISME* ще бъде множество от състояния на света.

Забележка: Защо интерпретацията на *ISME* е множество от състояния на света, а не е множество от *beliefs*? Защото считаме, че моделът на света е фиксиран. За всяко състояние на света *ISME* е или истина, или лъжа. Имаме *belief*, когато не знаем точно в кое състояние сме, но считаме, че светът „знае“ в кое състояние се намира. Ако сменим модела на света, тогава някое от състоянията на новия свят може да съответства на *belief* от състояния на стария. Сменяйки света, ще сменим и интерпретацията.

Интерпретацията дава смисъла на *ISME* в конкретен свят, но ние ще опишем *ISME* в произволен свят. Тоест ще погледнем нещата от гледната точка на агента, а не на света.

Възможното бъдеще може да се представи като дървото от възможните бъдещи развития. Ще приемем, че и възможното минало може да се представи като дърво. Тогава възможното минало и бъдеще могат да се представят като двойка дървета. Нека *All2* е множеството от всички двойки от такива дървета.

Дефиниция: Всяко подмножество на *All2* ще наричаме *ISME*.

Според тази дефиниция *ISMEs* са прекалено много. Ще опишем шест типа, които ще са важни за нас.

2.7.3.1 Винаги се случва

Пример за такова събитие е следното: „Събитието A винаги ще се случва в бъдеще“. (Аналогично за миналото: „Събитието A винаги се е случвало“.) Бихме искали да сложим някаква граница. Затова ще обобщим това събитие до следното: „Събитието A винаги ще

се случва в бъдеще до момента, в който се случи събитието B “. Ще запишем това събитие така: $A \text{ from } t \text{ until } B$.

Нормално е да потърсим евристики, които да предскажат това $ISME$. За целта ще използваме статистика върху жизнения опит. Избираме една конюнкция, която е кандидат за предпоставка на евристиката. Нека m пъти тази конюнкция е била истина и нека за k от тези случаи $A \text{ from } t \text{ until } B$ да е било истина. Тогава добър кандидат за коефициент на достоверност е k/m . Този коефициент не отчита това, че при малки m достоверността е малка, затова е по-добре да вземем $(k-1)/m$. Тогава коефициентът ще е по-малък от 100%, но ще клони към 100%, когато $k=m$ и когато m клони към безкрайност.

Нека в конюнкцията, която сме избрали, има невидимо събитие. Нека според някакви евристики това невидимо събитие да е истина. Тази информация можем да вземем от предположенията G_i . Ако има няколко предположения за невидимото събитие, тогава нека R е най-големият възможен коефициент на достоверност. В този случай ще добавим към броячите R вместо единица (броячите, където акумулираме k и m). Тоест ще отчетем това, че не е сигурно, че предпоставката е истина.

2.7.3.2 Ще се случи

Това събитие е подобно на събитието „ A винаги се случва“, но не може да бъде получено от него чрез две отрицания, защото така ще получим събитието: „ A може да се случи“. Последното означава, че по някой от пътищата на дървото на възможното бъдеще ще се случи A , но ние искаме A да се случи по всеки път (във всеки възможен живот).

Затова въвеждаме ново атомарно невидимо събитие: „винаги A се случва преди B “. Ще запишем това събитие така: $exist A \text{ after } t \text{ before } B \text{ in all cases}$.

Пак може чрез статистика да търсим евристики, които да ни предсказват това събитие. Само трябва да отбележим, че тук имаме и случая „не знам“. Този случай се получава, когато животът свършва преди да се е случило едно от събитията A или B . В този случай не знаем дали ако животът беше продължил, щеше първо да се случи A , или първо B .

Има разлика между „ $in \text{ our case}$ “ и „ $in \text{ all cases}$ “. Първото означава, че това ще се случи в нашия живот, а второто означава, че това ще се случи във всяко възможно продължение на бъдещето. Събитието „ $exist A \text{ after } t \text{ before } B \text{ in all cases}$ “ е невидимо, дори и когато A и B са видими.

2.7.3.3 Ще се случи с вероятност p

Събитието „ A се случва между t и B с вероятност p “ е различно от горните две събития. Горните две събития имаха свойствата, че запазват нулата и единицата. Едно събитие да запазва нулата означава, че: когато то е лъжа в две състояния, то е лъжа и във всеки $belief$, направен от тези две състояния. Аналогично и за свойството „запазва единицата“.

Горното събитие може да е лъжа в две състояния, но да е истина в $belief$, съставен от тях. Например нека в двете състояния A се случва с вероятности $1/4$ и $3/4$. Тогава от двете състояния може да направим $belief$, в който A се случва с вероятност $1/2$.

2.7.3.4 Достижимо събитие

Събитието „ A е достижимо“ е между събитията „ A може да се случи“ и „ A ще се случи“.

„А е достижимо“ означава, че съществува алгоритъм P , такъв че, ако агентът изпълнява P , тогава A ще се случи. Пример за алгоритъм е $Act(t+1)=a$. Разбира се, алгоритъмът може да бъде и по-сложен.

Как можем да намерим евристика за „А е достижимо“? Пак ще изберем една конюнкция, която е кандидат за предпоставка на евристиката. След това ще разгледаме различни случаи. За всеки от случаите ще намерим алгоритъм P и евристика, която ни казва, че ако предпоставка е налице и ако изпълним алгоритъма P , тогава A ще се случи. Ако сме покрили всички случаи, тогава можем да заключим, че при тази предпоставка A е достижимо.

2.7.3.5 Тестово събитие

В Dobrev (2017a) подробно са разгледани тестовите събития.

Пример за тестово събитие е: „Ако натиснем дръжката на вратата, то тя ще се отвори“. Това тестово събитие може да наречем „вратата не е заключена“. Стойността на тестовото събитие не зависи от това дали сме провели теста. Тоест вратата може да е заключена, независимо от това дали сме го проверили, или не сме.

2.7.4 Състояние на ED модел

Нека имаме един ED модел. Ще търсим интерпретация на този модел. За всяко състояние S_i на ED модела ще добавим свойството E_i , което ще е истина, когато ED моделът е в състоянието S_i . Ще търсим проста интерпретация, което значи, че предполагаме, че E_i е $ISME$.

За всяка стрелка на ED модела ще добавим по една евристика:

$$E_i(t) \& A(t) \Rightarrow E_j(t+1) \text{ (процент)}$$

Тук A е наблюдавано събитие и стрелката е по това събитие от S_i към S_j .

Частичната следа също ще я опишем по подобен начин. За всяка особеност ще добавим евристиката:

$$E_i(t) \Rightarrow A(t) \text{ (процент)}$$

Тук S_i е състоянието, A е събитието от особеността, а процентът отговаря на вероятността.

С помощта на тези евристики ще можем да предположим в кое състояние се намира ED моделът и с помощта на следата да предскажем допълнителните събития.

2.7.5 Полувидими събития

Заради некоректните ходове ще добавим полувидимите събития. За да разберем, че един ход е некоректен, трябва да се опитаме да го играем. Затова тези събития ще са между видимите и невидимите. Това ще са събития, които ще видим, ако погледнем.

Ще въведем едно атомарно събитие (*Correct*) и две евристики, които ще дефинират това събитие.

$$Act(t)=a \Rightarrow Correct(a, t) \text{ (100\%)}$$

Тази евристика ни казва, че ако в момента t сме изпълнили действието a , това означава, че в този момент действието a е било коректно. Следващата евристика ни казва, че ако в момента t сме се опитали да изпълним действието a и не сме успели, тогава в t действието a е било некоректно.

$$UnsuccessfulTry(a, t) \Rightarrow \neg Correct(a, t) \text{ (100\%)}$$

Предположението $UnsuccessfulTry(a, t)$ ще бъде едно различно предположение. То няма да се получава чрез евристики, а служебно ще го добавим в g_t всеки път, когато неуспешно сме се опитали да изпълним действието a в момента t . По този начин добавяме информацията за неуспешните опити.

Защо информацията за неуспешните опити я добавяме към предположенията? Предполагаме, че светът във всеки момент знае точно кой ход е коректен и кой е некоректен, но не знае кои от некоректните ходове агентът се е опитал да играе. При агента е обратното. Затова информацията за неуспешните опити ще е видима само за агента.

Двете служебни евристики, които добавихме, са с коефициент на достоверност 100%, но освен това може да има и други евристики, намерени чрез статистиката, които също да ни казват дали ходът е некоректен. Нормално е да предположим, че когато агентът се обучи, той ще знае кой ход е некоректен и това ще го знае, без да се е опитал да го играе. Това ще стане благодарение на допълнителните евристики, които ще му даде статистиката.

2.7.6 Нерелевантни събития

Освен релевантните събития, ще имаме и нерелевантни. Това са събития, които ще игнорираме и няма да се опитваме да разберем.

Ето три примера за такива събития.

1. „Кой живот живеем?“ – при положение че жизненият ни опит е последователност от много животи, можем да си зададем въпроса: кой поред е този живот?

Може да предположим, че светът във всеки живот се държи еднакво, но за агента е естествено да предполагаме, че той прави грешки от неопитност в първия живот и по-нататък тези грешки не ги допуска. Въпреки това ще игнорираме този въпрос и ще считаме, че той е нерелевантен.

2. „Колко съм стар и колко ми остава?“ – и този въпрос ще игнорираме. Тоест ще игнорираме параметрите t и $k-t$. Причината да игнорираме този въпрос е: считаме, че нашият агент е вечно млад и не старее с напредването на живота. Що се отнася до $k-t$, никой не знае колко му остава.

По-долу ще дефинираме разширения модел, в който t и $k-t$ имат значение, но ние се интересуваме само от събития, които, ако са верни в един живот, са верни и ако удължим живота (удължаваме напред и назад). Тоест нас ни интересуват само събития, които не зависят от t и $k-t$.

3. Събитията, които носят несъществена информация, също ще считаме за нерелевантни. В параграф 2.6.7 имаше такъв пример за това дали едно събитие се е случило четен или нечетен брой пъти.

2.7.7 Литературен обзор

Какво е събитие и кой въвежда понятието „събитие“ в ИИ? Първият, който въвежда това понятие, е Xi-Ren Cao. Той въвежда събитията в статията си Cao (2005).

По-късно, през 2008 г., Xi-Ren Cao заедно с Junyu Zhang в статията си Cao and Zhang (2008) дават дефиниция на понятието „събитие“. Тази дефиниция не е добра, защото зависи от модела и защото предполага, че се помни последното състояние, в което е бил моделът, а това е нещо, което няма причина да бъде запомнено. Ето как изглежда тяхната дефиниция на събитие:

$E \subseteq S \times S$, при конкретен модел

$E = \{ \langle s_{i-1}, s_i \rangle \mid \text{ако } E \text{ се случва в момента } i \}$

Защо тази дефиниция зависи от модела? Защото Cao и Zhang предполагат, че светът има само един-единствен модел, а това не е така. В Dobrev (2019a) е показано, че светът има много модели. Дори в Dobrev (2019a) е показано, че светът има минимален и максимален модел. Тук минимален и максимален е по отношение на това какво знаят състоянията в модела за миналото и за бъдещето.

Каква трябва да бъде дефиницията?

$E \subseteq S$, при произволен модел

$E = \{ s_i \mid \text{ако } E \text{ се случва в момента } i \}$

При различни модели състоянието може да „помни“ повече или по-малко от миналото. При дефиницията на Xi-Ren Cao състоянието помни последното състояние, в което е бил моделът. Както казахме, това е нещо, което няма причина да бъде запомнено. Ако решим да помним нещо, по-добре е да запомним последното действие на агента. Така ще е очевидно, че действията на агента са събития.

Дефиницията в Cao and Zhang (2008) не е свършена и може и трябва да се подобри, но това по никакъв начин не намалява заслугата на Xi-Ren Cao, защото той е първият, който забелязва, че не е достатъчно да наблюдаваме само действията и че трябва да обобщим до по-широк клас от събития.

Всъщност действията ни казват всичко, но те ни дават прекалено много информация. Когато моделът следи всички действия, той е зает и претоварен с прекалено много информация. Обобщавайки действията до произволни събития, ние ограничаваме входящата информация и можем да се ограничим до „важните“ неща.

Забележка: В *MDP* наблюденията не са сред проследените събития, но те се отчитат чрез следата. Следата уточнява кое е текущото състояние и по този начин се отчитат наблюденията.

Забележка: Терминът „събитие“ се използва в много статии, но обикновено в друг смисъл. Например в Lamperti, Zanella and Zhao (2020) терминът събитие се използва в смисъл на наблюдение. Наблюдението е частен случай на събитие, но при нас събитието е по-общо понятие.

2.8 Свят

За да създадем език за описание на светове, първо трябва ясно да кажем какво е свят. Ще дефинираме света чрез неговите свършени модели. Идеята е следната: представете си, че имате картина и нейно свършено копие, което е толкова добро, че не може да се различи копие от картината. В този случай може да приемем, че копие и картината са едно и също нещо.

Светът ще се състои от модел (който ще бъде *Simple MDP*) и от един начален *belief*, който ще ни покаже откъде се очаква да започне животът. Моделът ще искаме да е свършен (да не може да се подобри) и да е минимален.

Минималният модел не е единствен, дори и свършеният минимален модел не е единствен, но за всеки два свършени минимални модела можем да кажем, че състоянията на първия могат да се изразят като *belief* от състоянията на втория.

2.8.1 Минимален модел

Да е минимален един модел, означава състоянията му да не знаят нищо излишно. Тоест да не помнят нищо излишно от миналото и да не знаят нищо излишно за бъдещето. Ненужен (излишен) факт от миналото е такъв, който не влияе на бъдещето. Щом не влияе на бъдещето, тогава защо да го помним? Излишен факт за бъдещето е такъв, който не зависи от миналото (който не може да се предскаже с помощта на миналото). Има ли смисъл моделът да знае за бъдещето ненужни (излишни) неща? Например получили сте писмо, но още не сте го отворили, знае ли светът какво пише в писмото? Ще допуснем, че миналото по никакъв начин не може да ни помогне да предскажем какво пише в писмото. В този случай, какво пише в писмото е един факт, излишен за света, и той няма нужда да го знае, защото той може да реши това чак когато вие отворите писмото.

Разбира се, вие предполагате, че живеете в реален свят и че светът знае какво пише в писмото още преди да сте го отворили. Представете си, че живеете в компютърна програма (като филма „Матрицата“) и че светът решава какво да се случи в последния момент. Тоест решава какво пише в писмото не когато то е написано, а чак когато вие го отваряте.

Какво пише в писмото е факт, излишен за света, но не и за агента. Този факт е важен за агента, защото е свързан с неговото бъдеще. Този факт ще е непредсказуем за агента, защото не е свързан с миналото. Въпреки че е непредсказуем, агентът ще се опитва да го предскаже, защото няма как да знае, че този факт не може да бъде предсказан и че опитите му ще бъдат напразни.

2.8.2 Съвършен модел

Казахме, че състоянията на минималния модел не знаят нищо излишно. За състоянията на съвършения модел ще кажем, че знаят всичко полезно. Тоест, ако един модел е съвършен и минимален, тогава неговите състояния знаят точно това, което трябва (всичко полезно и нищо излишно).

Това, че моделът е съвършен, може да се каже по много начини.

1. Моделът притежава свойството на Марков.
2. Бъдещето зависи само от това от кое състояние тръгваме и не зависи от това как сме стигнали до това състояние.
3. Моделът не може да се подобри и да се направи друг модел, който на базата на миналото да дава по-добра прогноза за бъдещето.
4. Някое състояние не може да се раздели на две състояния, така че новите две състояния да имат различно минало и различно бъдеще. Да имат различно минало, означава на базата на това, което се е случило, да можем да ги различим. Да ги различим, означава да ги различим със сигурност или да кажем, че едното е по-вероятно от другото. Не е нужно всяко възможно минало да различава двете състояния. Достатъчно е да има едно възможно минало, което да ги различава. По аналогичен начин дефинираме какво означава две състояния да имат различно бъдеще.

Тези дефиниции на съвършен модел са еквивалентни. Състоянието на съвършения модел няма смисъл да се разделя надве, защото то знае всичко полезно. Ако на базата на миналото го разделим надве, то новите две състояния ще знаят още нещо за миналото, но това нещо няма да е нещо полезно и следователно двете състояния ще имат еднакво бъдеще.

Въпрос: ако вземем произволен модел, дали той е свършен модел на някой свят? Отговорът е „Да“. Всеки модел е свършен модел на някой свят. Всеки модел описва някакъв свят и ако предположим, че това е възможно най-доброто описание и че описанието не може повече да се подобри, тогава моделът е свършен. Разбира се, има безбройно много светове, за които този модел дава частично описание, което може да се подобри. Въпросът е дали сме намерили свършения модел на света, който се опитваме да опишем? Отговорът на последния въпрос е, че не знаем. Това, което знаем за света, е нашият жизнен опит. Има безбройно много светове, в които този опит може да се случи. Разбира се, ние търсим най-простия модел, отговарящ на нашия жизнен опит (този принцип е известен като „бръснача на Окам“).

Трябва да отбележим, че ние дори не сме сигурни, че моделът, който сме построили на базата на нашия жизнен опит, е коректен. В модела има някакви вероятности, които сме определили чрез статистика. Тези вероятности може да не са точни, поради малката статистика, но ако предположим, че статистиката е достатъчна и че вероятностите са точни, тогава остава само въпросът дали моделът е свършен.

Ние няма да търсим свършен модел на света. Ние ще търсим достатъчно добър модел, който да ни свърши работа. В Dobrev (2021b) показахме, че търсенето на свършен модел е прекалено амбициозна цел. Въпреки това ще предположим, че свършеният модел на света съществува и че този модел е дефиницията на света.

Също така няма да се опитваме да намерим минимален модел на света, защото това означава да приемем, че определени събития са непредсказуеми. Обикновено ние се опитваме да предскажем всяко събитие, макар че за някои събития (като хвърлянето на зар) приемаме, че резултатът е непредсказуем.

2.8.3 Базов модел

Дефиниция: Базов модел на света ще бъде всеки свършен и минимален модел на света.

Ще предположим, че всеки свят си има поне един базов модел и това ще е определението на този свят. Един модел може да е базов за един свят (да е свършен), но за друг свят той може да е обикновен модел (да не е свършен).

Състоянията на базовия модел знаят всичко за миналото (какво би могло да се е случило) и всичко за бъдещето (какво би могло да се случи).

Забележка: Някои автори използват различна терминология. Например в Schofield and Thielscher (2019) се използва терминът „игра“ вместо „свят“. Също така в Schofield and Thielscher (2019) се използва терминът *Game Description Language* вместо *Language for Description of Worlds* и *Imperfect Information* вместо *Partial Observability*. Можем да разглеждаме света като игра, както и играта като отделен самостоятелен свят. Както се пее в песен на група *Mystery: The World is a Game*.

2.8.4 Simple MDP

Обикновено светът се описва чрез *Markov decision process (MDP)*. Ние ще опростим този модел и ще създадем *Simple MDP*.

Защо е нужно *MDP* да се опрости? Защо в *MDP* има излишно усложняване? Причините за това са две.

Първата причина е, че *MDP* крие факта, че това е модел не само на света, но и на агента. Истината е, че светът и агентът са единна система и не можем да опишем само

едното, без да описваме другото. Тоест *MDP* описва не само поведението на света, но и поведението на агента. Ако се вгледате в *MDP*, ще видите, че *MDP* казва, че агентът прави каквото си иска. Да правиш каквото си искаш, това също е поведение, макар и това да е възможно най-свободното поведение. Каква е вероятността агентът да избере определено действие? Не знаем каква е тази вероятност – агентът прави каквото си иска, което означава, че вероятността е в интервала $[0, 1]$.

Втората причина е, че *MDP* ограничава света и го принуждава да използва една точно определена фиксирана стратегия. Тоест при *MDP* агентът прави каквото си иска, а светът е ограничен до фиксирана стратегия.

2.8.5 Фиксирана стратегия

Какво е фиксирана стратегия? Ако при определена ситуация завивате винаги наляво, това означава, че изпълнявате фиксирана стратегия. В този случай стратегията дори е екстремна, защото винаги наляво и винаги надясно са двете екстремни възможности. Ако хвърляте монета и когато се падне ези, завивате наляво, тогава вие изпълнявате фиксирана стратегия с вероятност $1/2$ (точно $1/2$). Ако вероятността е друга, тогава и фиксираната стратегия, която изпълнявате, е друга. Ако завивате наляво или надясно както си поискате, тогава вие не изпълнявате фиксирана стратегия, а завивате наляво с вероятност, която е в интервала $[0, 1]$.

Имате ли свободна воля, когато изпълнявате фиксирана стратегия? Отговорът е „Не“. Когато хвърляте монета, тогава не решавате вие, а монетата. Тоест при *MDP* агентът има напълно свободна воля и не е ограничен от нищо, а светът е напълно ограничен и е принуден да изпълнява фиксирана стратегия.

2.8.6 Екстремна стратегия

Екстремната стратегия е фиксирана стратегия, която е избрана така, че всяка вероятност е на минимума или на максимума.

Как избираме екстремна стратегия? Ако вероятностите са определени с интервалите $[a_i, b_i]$, тогава избираме стойността на един от интервалите екстремно (т.е. избираме a или b). Ако сме избрали b , това може да стесни останалите интервали. След това от останалите (евентуално стеснени) интервали избираме един от тях и продължаваме нататък. По този начин избираме фиксирана стратегия, в която всяка вероятност е екстремна (тоест не може да се увеличи или не може да се намали).

Когато говорим за стратегия в *Simple MDP*, ще имаме предвид обща стратегия на агента и на света. Тоест двамата са се наговорили и играят две стратегии, които, взети заедно, са общата стратегия на *Simple MDP*. Когато се говори за стратегия на *MDP*, се има предвид стратегия само на агента, защото светът в *MDP* има фиксирана стратегия и няма накъде да мърда. Кого се говори за стратегия на агента в *MDP*, се има предвид екстремна стратегия (всяка вероятност е или 0, или 1). Защо в *MDP* екстремните стратегии са достатъчни? Когато преследваме една цел и трябва да решим „наляво или надясно“, тогава обикновено има три възможности. За нашата цел по-добре е наляво, по-добре е надясно или все едно е дали наляво или надясно. Ако приемем, че в третия случай избираме наляво, тогава получаваме екстремна стратегия. Затова в *MDP* екстремните стратегии са достатъчни. Разбира се, това не важи за всяка цел. Ако целта е разнообразието (т.е. да обиколим повече), тогава трябва да редуваме ляво и дясно.

Хубавото на екстремните стратегии е, че когато състоянията са крайно много, тогава и екстремните стратегии са крайно много, докато фиксираните стратегии обикновено са континуум.

2.8.7 От *MDP* към *Simple MDP*

С *MDP* можем да опишем само част от световите. Това са едни много специални светове, в които светът няма свободна воля и е принуден да изпълнява фиксирана стратегия. Ако вътре в света живее агент със свободна воля, този свят не може да се опише с *MDP*. Нека разгледаме света на играта шах, в който има втори агент, който играе срещу главния герой. Нека този втори агент не е детерминиран (не играе екстремна стратегия). Нека дори да не е длъжен да играе с фиксирана стратегия. Нека този агент да играе както си поиска. Тогава този свят не може да се представи с *MDP*, но ще можем да го представим чрез *Simple MDP*. Разликата между двата модела е, че вместо точни вероятности, в *Simple MDP* имаме вероятностни интервали.

MDP е излишно усложнен, защото е скрито, че вероятността на действията на агента е интервалът $[0, 1]$. Върху стрелките с действия има вероятности, но тези вероятности не определят вероятността на действието, а индиректно определят вероятността на наблюдението. (Наблюдението влияе върху това кое ще е следващото състояние на *MDP* модела, но това влияние е много сложно и индиректно. Стрелките недетерминирано определят няколко възможни състояния и на база на наблюдението някои от тези състояния отпадат. При *Simple MDP* нещата са много по-прости, защото там има стрелки по наблюденията и тези стрелки директно ни показват как ще повлияе наблюдението на това кое е следващото състояние.)

В *MDP* състоянието има минало, настояще и бъдеще. Тоест нещо се е случило преди състоянието, нещо се случва вътре в състоянието и нещо ще се случи след състоянието. В *Simple MDP* има само минало и бъдеще, защото нищо не се случва вътре в състоянието. В състоянието на *MDP* има някакво наблюдение. Има две еквивалентни дефиниции на *MDP*. Ще ги наречем едноцветна и многоцветна дефиниция. При едноцветната дефиниция има само едно възможно наблюдение в състоянието, а при многоцветната в състоянието има няколко възможни наблюдения, всяко от които с точно определена вероятност. Тоест при едноцветната дефиниция моделът не е минимален, защото състоянието „знае“ кое точно ще е наблюдението, а това знание може да не следва от миналото. Може миналото да дава недетерминистичен преход към няколко едноцветни състояния. Минималност ще се получи, ако тези няколко едноцветни състояния бъдат заменени с едно многоцветно, в което всяко наблюдение да се вижда със съответната вероятност.

2.8.8 Дефиниция на *Simple MDP*

Ще представим *Simple MDP* като *finite automaton* (без изискването броят на състоянията да е краен). По-точно ще го представим като *probabilistic automaton*, защото върху стрелките ще имаме вероятности. Още по-точно ще го представим като *interval-valued probabilistic automaton*, защото вместо вероятности върху стрелките ще има вероятностни интервали.

При *MDP* състоянията са само от един тип, защото там винаги агентът е на ход. При *Simple MDP* ще разгледаме света като игра между агента и света. Там състоянията на света ще са два типа – състояния, при които агентът е на ход, и такива, при които светът е на ход.

При *MDP* стрелката отговаря на един ход. Това е действие на агента и реакция на света. (Реакцията на света е наблюдението, което вижда агентът.) При *Simple MDP* стрелката ще отговаря на *ply* (полуход). Това или е действието на агента, или е реакцията на света.

Дефиниция: *Simple MDP* ще бъде граф $(U \cup W, A \cup O)$ с два вида върхове и два вида стрелки.

- U са състояния на света, когато агентът е на ход (ще извърши действие).
- W са състояния на света, когато светът е на ход (ще покаже наблюдение на агента).
- A са стрелки, отговарящи на действия.
- O са стрелки, отговарящи на наблюдения.
- Ако $u \in U$, тогава стрелките, излизащи от u , са от A и стрелките, влизащи в u , са от O .
- Ако $w \in W$, тогава стрелките, излизащи от w , са от O и стрелките, влизащи в w , са от A .
- $A \rightarrow \Sigma \times [0, 1] \times [0, 1]$, на всяка стрелка от A съответства действие и вероятностен интервал.
- $O \rightarrow \Omega \times [0, 1] \times [0, 1]$, на всяка стрелка от O съответства наблюдение и вероятностен интервал.

Трябва да кажем още нещо за вероятностните интервали. Когато вероятността е фиксирана (интервали с дължина нула), тогава сумата от вероятностите на стрелките, излизащи от един връх, трябва да е единица. Когато вероятността не е фиксирана, тогава вероятностните интервали (на стрелките, излизащи от един връх) ги разглеждаме като описание на множество от вектори от фиксирани вероятности, всеки от които има сума, равна на единица. Тоест интервалите $[a_i, b_i]$ описват вектора p_i , където $a_i \leq p_i \leq b_i$ и $\Sigma(p_i) = 1$. Ще искаме това описание да описва поне един вероятностен вектор (т.е. множеството от описаните вектори да не е празното). Ще искаме още описанието да е оптимално (т.е. при всяко стесняване на интервалите да се губи по някой вектор от множеството). В Dobrev (2017b) са дадени няколко неравенства, които трябва да са изпълнени, за да бъде описанието непразно и оптимално.

2.8.9 MDP като Simple MDP

Как можем да представим *MDP* като *Simple MDP*? Всички стрелки в *MDP* са по действие, тоест са от тип A . Всяка стрелка си остава, само вероятността ѝ p се заменя с интервала $[0, p]$. Тоест, ако агентът избере това действие, тогава ще избере тази стрелка с вероятност p , а в противен случай ще я избере с вероятност 0. В случаите, когато действието е само едно (няма стрелки по други действия, излизащи от същото състояние), тогава p се заменя с интервала $[p, p]$.

Как променяме състоянията? Всяко състояние s се заменя с две състояния w и u , които ще са от типове W и U съответно. Всички стрелки, които досега са влизали в s , сега ще влизат в w , а тези, които са излизали от s , сега ще излизат от u . Колкото са били възможните наблюдения ob в s , толкова допълнителни стрелки ще добавим от w към u . Всяка стрелка ще е от тип O , ще бъде по съответното наблюдение ob и ще ѝ съответства вероятностният интервал $[p, p]$, където p е вероятността на наблюдението ob . Какво правим в случая на едноцветна дефиниция (т.е. когато всяко състояние има само по едно

наблюдение)? Тогава стрелката от w към u ще е само една и тя ще е с вероятностния интервал $[1, 1]$.

Така полученият *Simple MDP* ще описва същия свят като модела *MDP*. Ако моделът *MDP* е бил съвършен, тогава и полученият *Simple MDP* ще бъде съвършен. Същото важи и за минималността.

Покажахме, че всички светове, които могат да се представят като *MDP*, могат да се представят и като *Simple MDP*, но не и обратното. Тоест *Simple MDP* разширява идеята ни за свят.

2.8.10 Начален *belief*

За да опишем света, ще трябва да добавим още едно начално състояние. Ние ще предпочетем началното състояние да не е едно, а да бъде множество от възможни начални състояния. Всяко едно от тези възможни състояния ще има някаква вероятност. Ако тази вероятност е фиксирана, ще получим една структура, която ще наречем „фиксиран *belief*“.

Дефиниция: Фиксиран *belief*:

- $M \subseteq U \cup W$
- $M \rightarrow [0, 1]$

Тоест имаме множество от състояния и на всяко състояние от множеството сме съпоставили фиксирана вероятност. Сумата от тези фиксирани вероятности трябва да е равна на единица. Тук няма да има съществена разлика между $s \notin M$ и вероятността на s да е нула. В повечето статии това, което ние наричаме фиксиран *belief*, се нарича *belief*, но при нас *belief* ще е нещо по-сложно.

Дефиниция: „Обобщен *belief*“ ще наричаме множество от фиксирани *beliefs*.

За по-кратко ще наричаме обобщения *belief* просто *belief*.

Ще предполагаме, че светът се описва чрез един *Simple MDP* и един начален *belief*. Кое е началното състояние, от което очакваме да тръгнем? Първо избираме един фиксиран *belief* от тези, които са елементите на началния *belief*. Как го избираме? Избираме го, както си искаме, тук имаме случайност с неизвестна вероятност. След това от избрания фиксиран *belief* избираме едно конкретно начално състояние с вероятността, която е дадена от този фиксиран *belief*.

Смисъл на понятието начален *belief* може да се даде от жизнения опит и статистиката на света. Това е очакването за това кое ще е началното състояние на света.

2.9 Интерпретация

Вече казахме какво е интерпретация на *ED* модел, но още не сме казали какво е интерпретация на събитие.

Ще въведем разширения модел. Този модел ще се получи от базовия, като добавим миналото и бъдещето. Тоест състоянията на базовия модел знаят какво може да се е случило и какво може да се случи, а състоянията на разширения модел освен това ще знаят още какво точно се е случило да момента и какво точно ще се случи от този момент нататък.

Интерпретация на събитие ще бъде множество от състояния на разширения модел. Всяко събитие ще си има вероятност, защото всяко състояние на разширения модел ще си има вероятност.

За да опростим изложението, ще предположим, че светът е обзрим. Обозримостта се характеризира с две неща:

1. Всяко събитие, което се е случило, може пак да се случи.
2. Началният *belief* е неподвижният *belief*. Тоест въпросът „В кое състояние очакваме да сме в първия момент?“ съвпада с въпроса „В кое състояние очакваме да сме в произволен момент?“.

Предимство на обзиримия свят е, че при него обратната вероятност не зависи от t . Също така за всяко състояние на базовия модел можем да дефинираме вероятност и тази вероятност също няма да зависи от t .

2.9.1 Възможно бъдеще

Възможното бъдеще е последователност от действия, наблюдения и множества от некоректни ходове. Това са крайни множества и затова възможното бъдеще е дума над азбука с $n+m+2^m$ букви.

За всяко състояние s ние можем да опишем възможното бъдеще като безкрайно дърво, съдържащо всички думи, които могат да се получат като бъдеще, ако тръгнем от s . На всеки връх в това дърво ще съответства дума (възможно бъдеще) и вероятност (вероятностен интервал).

Вероятността е равна на произведението на вероятностите, които сме събрали в *Simple MDP* модела, тръгвайки от s и прочитайки тази дума. (На стрелките съответстват действия и наблюдения, а на състоянията от U съответстват множества от некоректни ходове.) Ако тази дума може да се прочете по повече от един начин, тогава вероятността е равна на сумата от различните вероятности, които биха се получили по различните начини.

В случая, когато вероятността е интервал, трябва да кажем как се събират и умножават вероятностни интервали.

Умножение:

$$[a_1, b_1] \cdot [a_2, b_2] = [a_1 \cdot a_2, b_1 \cdot b_2]$$

Събиране:

$$[a_1, b_1] + [a_2, b_2] = [a_1 + a_2, \min(b_1 + b_2, 1)]$$

Стрелките по действия не могат да са повече от една (излизащи от един връх и по едно и също действие), но стрелките по наблюдения могат. Когато всички ходове са коректни, тогава дървото е просто и стрелките по наблюдения също не могат да се разклоняват. Когато има некоректни ходове, дървото е по-сложно, защото от един връх може да излизат няколко стрелки по едно и също наблюдение, но те ще отиват във върхове, на които съответстват различни множества от възможни ходове.

Ще считаме, че на никоя от стрелките не отговаря вероятност нула. Ако има такава вероятност, ще отстраним това поддърво. Ако позволим да има стрелки с вероятност нула, тогава дървото няма да е единствено.

2.9.2 Възможно минало

Искаме да дефинираме възможното минало по същия начин, както дефинирахме възможното бъдеще. Тук обаче имаме проблем. За всяка стрелка ще ни трябва обратната вероятност. Това е вероятността да сме дошли от тази стрелка. (Ние вече имаме

нормалната вероятност, но тя е нещо друго, тя е вероятността да сме тръгнали по стрелката.)

Можем да дефинираме обратната вероятност чрез статистиката на света. Тя ще бъде k/m , но тук m ще бъде колко пъти сме минали през главата на стрелката (а не през опашката ѝ). Проблемът е, че когато дефинирахме нормалната вероятност, ние предположихме, че тя е постоянна и не зависи от t (т.е. не зависи от това на коя стъпка сме), а когато дефинираме обратната вероятност, може да се окаже, че тя зависи от t .

За да сметнем обратната вероятност, ще ни трябва нормалната вероятност и още нещо. Това още нещо е вероятността на всяко от състоянията. Тази вероятност в първия момент ние представяме чрез начален *belief*. За всеки следващ момент ние можем да изчислим следващия *belief* чрез предишния *belief* и нормалната вероятност.

Формулите за целта са следните:

$$\begin{aligned}m_i \cdot p_i &= m \cdot q_i \\ q_i &= \frac{m_i \cdot p_i}{m} \\ m &= \sum m_i \cdot p_i\end{aligned}$$

Тук q_i са обратните вероятности на някакво състояние s . Индексът i пробягва предишните състояния (тези, от които излиза стрелка, влизаща в s). Вероятностите p_i са нормалните вероятности на стрелките, излизащи от предишните състояния и влизащи в състоянието s . Вероятностите m_i са получени от предишния *belief*. Това са вероятностите да сме в някое от предишните състояния в предишния момент, а m е вероятността да сме в състоянието s в следващия момент.

Първото равенство получаваме от това, че вероятността да излезем от едно състояние по една стрелка е равна на вероятността да влезем в следващото състояние по същата стрелка. Горните формули определят еднозначно обратните вероятности q_i винаги освен в един случай. Това е случаят, когато $m=0$. В този случай можем да поставим на q_i каквито си искаме стойности (стига сумата на q_i да е равна на единица).

По този начин за всяка стъпка t получаваме *belief* и обратни вероятности, които зависят от стъпката t . Възможното бъдеще дефинирахме като едно безкрайно дърво, а възможното минало ще бъде много по-сложно. То ще бъде изброимо множество от дървета. За момента 0 няма да имаме минало (т.е. дърво с дълбочина 0). За момента t възможното минало ще се представя чрез дърво с дълбочина t .

Бихме искали възможното минало също да е просто, както възможното бъдеще. За целта ни трябва очакването за това в кое състояние сме да е постоянно и да не зависи от стъпката t .

2.9.3 Минало vs Бъдеще

В тази дисертация миналото и бъдещето са напълно симетрични. Идеята за тази симетрия идва от факта, че представяме живота като път в един граф. Няма разлика дали ще вървим напред по посока на стрелките, или ще вървим назад в обратна посока.

На пръв поглед изглежда, че има разлика между вероятностите напред и назад, но всъщност и там няма разлика. Вероятностите напред са постоянни, а тези назад зависят от t , но това е, защото първо задаваме вероятностите напред и по тях определяме вероятностите назад. Ако бяхме подхождали наобратно (ако бяхме задали първо вероятностите назад и по тях да определим вероятностите напред), тогава вероятностите

назад щяха да са постоянни, а тези напред щяха да зависят от $k-t$. Разбира се, за да вървим наобратно, би трябвало да зададем заключителен вместо начален *belief*. Тоест ще трябва да тръгнем от някакъв заключителен *belief*.

По-долу ще въведем понятието „обозрим свят“. Това ще е специален свят, при който вероятностите напред и назад не зависят от t . Тоест ще покажем, че в интересния случай миналото и бъдещето са съвсем симетрични.

2.9.4 Свободна воля

Предположиме, че светът и агентът могат да имат свободна воля. Тоест предполагаме, че светът и агентът могат да правят каквото си искат (но в някакви граници). Описваме света чрез статистиката и затова играчите трябва да използват свободата си, защото ако те не я използват, моделът няма да я отчете.

Ако светът и агентът не използват напълно свободата си, чрез статистиката ще получим стеснен модел на света, който ще отрази реалното поведение на играчите.

Например при играта шах светът и агентът имат някакви коректни ходове и могат да играят всеки един от тях. В действителност, те не играят всеки коректен ход. Например можем да предположим, че те не правят елементарни грешки. Ако чрез статистиката направим модел на играта шах, вероятно ще получим модел, в който вероятностните интервали са по-тесни. Тоест ще получим модел, в който възможните ходове са по-малко. Това ще отрази реалното поведение на агента и на неговия противник (има възможни ходове, които те двамата никога не играят).

В играта шах има едно правило: „Не е позволен ход, ако след този ход противникът може да ти вземе царя“. Може да се каже, че такъв ход би бил елементарна грешка и че правилата на играта забраняват тази елементарна грешка. Тоест това правило намалява броя на коректните ходове. Ако забраним и други елементарни грешки, ще получим още по-стеснен модел, в който поведението на света и агента е още по-ограничено.

2.9.5 Неподвижен *belief*

Искаме началният *belief* да е такъв, че следващият *belief* да е същият и всеки следващ *belief* да е същият. Тоест искаме началният *belief* да е неподвижен (неподвижна точка).

Дефиниция: „Капан“ ще наричаме група състояния, в които може да се влезе, но връщане назад няма.

Ако в света няма капани, тогава всяка компонента на свързаност е силно свързан граф. Нека да предположим, че във всяка компонента на свързаност сме избрали една силно свързана компонента и нека тя да е главната (ще я наречем ядрото на компонентата на свързаност). В света няма капани точно тогава, когато няма вливащи се и изтичащи пътища.

Дефиниция: „Вливащ се път“ (*inflow*) ще наричаме група състояния, от които може да се влезе в ядрото, но връщане назад няма.

Дефиниция: „Изтичащ път“ (*outflow*) ще наричаме група състояния, в които може да се влезе от ядрото, но връщане назад няма.

За да има неподвижен *belief*, трябва вероятностите върху вливащите се и изтичащите пътища да са нула. Освен това трябва вероятността да влезем в изтичащ път да е нула, защото в противен случай постоянната вероятност ще изтече в изтичащия път. Това

е причината, поради която е по-добре да предполагаме, че тези пътища ги няма. Щом вероятността им е нула, все едно ги няма.

2.9.6 Обозрим свят

Първо ще кажем какво е компактен свят.

Дефиниция: Компактен свят ще бъде такъв, в който няма вливащи се и изтичащи пътища.

Дефиниция: Обозрим свят ще бъде такъв, който:

1. Между всеки две състояния има път (силно свързан граф).
2. Вероятностният интервал на всяка от стрелките е различен от нула (т.е. може да е $[0, p]$, но не може да е $[0, 0]$).
3. Началният *belief* на света е множеството от всички неподвижни фиксирани *beliefs*.

Първото условие означава, че обозримият свят е компактен и че е с една компонента на свързаност. Второто условие гарантира, че във всяко състояние можем да попаднем с някаква вероятност, при известно съдействие на света и на агента (чрез тяхната свободна воля). Третото условие означава, че тези два въпроса имат един и същи отговор.

1. От кое състояние очакваме да тръгнем?
2. Кое е състоянието, в което очакваме да се намираме след много дълъг живот, без значение от кое състояние сме тръгнали?

Ще предполагаме, че светът е компактен и дори че е обозрим. Предимството на компактния свят е, че обратните вероятности са еднозначно определени и възможното минало е просто (то е едно дърво). Предимство на обозримия свят е, че можем еднозначно да определим неподвижния *belief* и по този начин по-простичко да дефинираме разширения модел. В противен случай очакването да се намираме в определено състояние ще зависи от t и разширеният модел ще е по-сложен.

В Dobrev (2000) предположихме, че търсим ИИ, който ще се справи добре в световите, в които няма фатални грешки. Предположението в Dobrev (2000) беше, че ако се справя добре в такива светове, ще се справи добре и в произволен свят. Същото предположение можем да направим и за обозримите светове.

Можем ли да кажем, че ако един свят е обозрим, то в него няма фатални грешки? По-долу ще видим, че ако светът е обозрим и ако светът не е враждебен, то тогава никоя грешка не е фатална. Какво значи светът да е враждебен? Казахме, че светът има известна свободна воля и може да избере своята фиксирана стратегия измежду определено множество от фиксирани стратегии. Ако светът е враждебен, той може целенасочено да избира своята стратегия срещу агента. Тогава агентът може да попадне във вдлъбнатина и да не може да излезе от нея, защото светът не го пуска да излезе. Ако светът не е враждебен (т.е. ако е безпристрастен или е благосклонен и се опитва да помага), тогава агентът не може да попадне във вдлъбнатина, от която да не може да излезе, и тогава няма да има фатални грешки.

2.9.7 Единствен *belief*

Кога неподвижният фиксиран *belief* е единствен? Ще разгледаме по-простия случай, когато имаме фиксирана стратегия (т.е. вероятностите p_i са фиксирани). Нека още вероятностите p_i да са различни от нула. Нека още светът да е обозрим.

В този случай имаме единствен неподвижен *belief* (той ще е фиксиран). Можем да го изчислим, като решим система от уравнения. Друг начин за получаването на този фиксиран *belief* е чрез статистиката на света. Можем да вземем един много дълъг живот. Няма значение от кое състояние ще сме тръгнали. Тогава нека m е вероятността да сме в състоянието s . Тази вероятност ще клони към това, което ни дава този *belief*. Не става дума за вероятността в момента t , а за средната вероятност, защото вероятността може да се движи на вълни и вероятността в момента t може да не е сходяща, но средната вероятност е сходяща.

Тоест получихме един неподвижен *belief*, който отговаря на естествения въпрос: в кое състояние очаквате да се намира светът?

Нека светът сега да не е обозрим, а да е компактен и да има два компонента на свързаност. Тогава неподвижният *belief* няма да е единствен, защото може да разпределим вероятността между двата компонента на свързаност в произволно съотношение (например 1:1 или 1:2).

Нека сега светът да е обозрим, но във фиксираната стратегия, която сме избрали, да има вероятности, равни на нула. Тогава тази стратегия разделя света на вдлъбнатини с плоско дъно и околности на вдлъбнатините. Попадайки на дъното на вдлъбнатина, повече не можем да излезем. Ако сме тръгнали от околност на вдлъбнатина, ще попаднем на дъното на тази или на някоя друга вдлъбнатина. В този случай неподвижният *belief* няма да е единствен, защото в околностите на вдлъбнатините вероятността ще е нула (тя ще е разпределена по дъната). Проблемът е, че вероятността може да се разпредели по различните дъна в произволно съотношение.

Как в този случай да направим един-единствен *belief*? Ще разгледаме границата, когато вероятностите p_i са различни от нула, но клонят към тези, които имаме. Така ще намерим естественото разпределение на вероятностите върху различните дъна. Така намираме единствен неподвижен *belief* при фиксирана стратегия.

Ако вземем множеството на всички фиксирани стратегии (които са в тези вероятностни интервали), ще получим множество от фиксирани *beliefs* и това ще е обобщеният *belief*, който ще ни отговаря на въпроса „В кое състояние очаквам да съм?“.

Този обобщен *belief* ни дава за всяко състояние на базовия модел по един вероятностен интервал. Този интервал ще ни даде вероятността да се намираме в дадено състояние на базовия модел. Ще означим този интервал с функцията *expected(s)*.

2.9.8 Разширен модел

Казахме, че в базовия модел състоянията знаят всичко полезно и нищо излишно. В разширения модел ще добавим една излишна информация. Ще добавим целия живот (гръбнака и следата на живота). Тази информация е „излишна“, защото състоянието на базовия модел „знае“ какво е възможното минало и възможното бъдеще, но не знае какво точно е било миналото и какво точно ще бъде бъдещето.

Множеството от състоянията на разширения модел ще бъде S' .

$$S' = \{ \langle t, L \rangle \mid 0 \leq t \leq k, L \text{ is possible life} \}$$

Тук $k = |L|$. Какво наричане „възможен живот“? Това е произволен краен път в графа, който описва базовия модел. (Всяко състояние може да е началното, защото предположихме, че светът е обозрим.)

Множеството S' ще наречем „множеството на моментите“, защото всеки момент от всеки възможен живот е елемент на това множество.

Ако разгледаме разширения модел като граф, той ще има много проста структура, състояща се от непресичащи се нишки. Всяка нишка ще отговаря на един възможен живот.

Състоянието на разширения модел ще знае точно какво се е случило и какво ще се случи, но това не означава, че ако знаем миналото и модела, ще можем да кажем какво ще е бъдещето. Вярно е, че състоянието „знае“ всичко, но ние няма откъде да знаем точно в кое състояние сме.

Когато $t=0$, тогава началният *belief* определя в кое състояние на разширения модел сме. Новият начален *belief* ще получим от множеството S_0' като на всяко състояние добавим вероятността $expected(<0, L>)$ (тези дефиниции са дадени по-долу).

$$S_0' = \{ <0, L> \mid L \text{ is possible life} \}$$

Тоест новият начален *belief* ще съдържа началния момент на всеки възможен живот. Това са много елементи, защото дори и да фиксираме началното състояние u_0 , то елементите в новия начален *belief* пак ще са изброимо много, защото възможните животи, започващи с u_0 , са изброимо много (заради различните дължини и заради разклоненията). Тоест състоянието $<0, L>$ „знае“ всичко за бъдещето, но ние няма да го знаем, защото няма откъде да знаем, че се намираме точно в състоянието $<0, L>$.

Функцията *expected*, която е дефинирана за състоянията на базовия модел, ще я продължим, като я дефинираме за моментите (състоянията на разширения модел). За целта ще вземем вероятността на живота L и ще я разделим на броя на моментите в L .

Искаме сумата от вероятностите на всички пътища да е единица и затова ще предположим, че вероятността пътят да е с дължина k е $(1-\lambda) \cdot \lambda^k$. (Тоест разпределяме единицата върху всички възможни дължини на пътя.) Тук ще изберем един коефициент λ , но изборът на този коефициент не е съществен, защото предположихме, че събитията запазват верността си при разширяване на живота. (Формулата за *expected* ще зависи от L , но не и от t , защото вероятността е разпределена равномерно между моментите от живота.)

$$expected(<t, L>) = \frac{expected(s_0) \cdot p_1 \cdot p_2 \cdot \dots \cdot p_k}{k+1} \cdot (1-\lambda) \cdot \lambda^k$$

Тук $k=|L|$, s_0 е първото състояние от живота L , p_i е вероятността на стрелката от s_{i-1} към s_i . Нека q_i е обратната вероятност на стрелката от s_{i-1} към s_i . Тогава вероятността на един живот с дължина k да бъде животът L можем да запишем по три начина:

$$\begin{aligned} & expected(s_0) \cdot p_1 \cdot p_2 \cdot \dots \cdot p_k \\ & q_1 \cdot q_2 \cdot \dots \cdot q_k \cdot expected(s_k) \\ & q_1 \cdot \dots \cdot q_t \cdot expected(s_t) \cdot p_{t+1} \cdot \dots \cdot p_k \end{aligned}$$

Тоест можем да започнем от вероятността на което и да е от състоянията от гръбнака на живота и да го умножаваме по вероятността да се премине към следващото (или към предишното) състояние.

Дефиниция: „Интерпретация на събитието A “ ще наричаме две множества P и Q , където P са моментите, когато A се случва, Q са моментите, когато A не се случва, а в останалите моменти не знаем дали A се случва.

Дефиниция: Вероятността на събитието A ще бъде:

$$expected(A) = \frac{expected(P)}{expected(P) + expected(Q)}$$

Тоест вероятността се определя от моментите, в които знаем каква е стойността на събитието.

Предположихме, че събитията запазват верността си при разширяване на живота, което означава, че предполагахме, че множествата P и Q са затворени спрямо операцията разширяване на живота.

Дадената от нас дефиниция на събитие зависи от избрания базов модел. При друг базов модел, други ще са множествата P и Q . Въпреки това събитието ще е същото, защото ще има същата вероятност и ще се държи по същия начин спрямо следата на живота.

2.9.9 MDP като ED модел

Като приложение на горното ще покажем, че MDP е частен случай на ED модел. В MDP моделите наблюдаваните събития са действията на агента:

$$act(t)=a_i, 1 \leq i \leq m$$

Тези събития не се пресичат и затова нямаме нужда от правила за разрешаване на колизиите. Допълнителните събития (тези, които участват в частичната следа) са текущите наблюдения:

$$ob(t)=o_i \vee ob(t+1)=o_i, 1 \leq i \leq n$$

Тук не е ясно дали t е четно, или нечетно и дали текущото наблюдение току-що се е случило, или ще се случи на следващата стъпка. Затова събитието се определя с дизюнкция.

2.9.9.1 Fully observable Markov decision process

Първо ще разгледаме *Fully observable MDP (FOMDP)*. В този случай топологията на ED модела е проста. Той има n състояния (колкото са възможните наблюдения) и между всеки две състояния, по всяко действие, има стрелка. Следата на ED модела е ясна и хубава. Във всяко състояние има едно текущо наблюдение, което се случва с вероятност единица (всяко състояние се разпознава еднозначно по текущото наблюдение). Единственото, което трябва да добавим, за да определим модела $FOMDP$, са вероятностите по стрелките:

$$p_{iaj} = expected(ob(t+2)=o_j | ob(t)=o_i \& act(t+1)=a) \quad (1)$$

Тоест следващото наблюдение е o_j , при условие че предишното наблюдение е било o_i и последното действие е било a . Трябва да кажем какво е събитие при условие. Това събитие ще е истина или лъжа, когато условието е изпълнено, и ще бъде „не знам“, когато условието не е изпълнено.

Функцията *expected* може да върне фиксирана вероятност или да върне вероятностен интервал. Когато в (1) *expected* връща фиксирани вероятности, ще получим класическата дефиниция на $FOMDP$. Разбира се, нищо не ни пречи да обобщим дефиницията на $FOMDP$ и да позволим да има преходи, които не са точна вероятност.

Забележка: $FOMDP$ има една-единствена еднозначна интерпретация и тя се определя от събитието „Кое е текущото наблюдение?“. За всеки момент от живота ние знаем кое е текущото наблюдение, с изключение на първия момент (момента нула). Това, че не знаем кое е текущото наблюдение в първия момент, не е проблем, защото

интерпретацията не е нужно да бъде дефинирана за краен живот. Тя трябва да е дефинирана върху всеки безкраен живот, а в безкрайния живот няма първи момент.

Така получихме модел с n състояния и матрица p_{iaj} на вероятностите на преходите. Този модел е известен в литературата като *Fully observable MDP*. Изниква въпросът дали този модел изпълнява свойството на Марков, тоест дали моделът е съвършен (най-добрият възможен модел, който да не може повече да се подобри).

От една страна, е добре моделът да изпълнява свойството на Марков, защото това означава, че сме намерили най-доброто възможно решение. От друга страна, това не е добре, защото означава, че сме достигнали една граница, която не можем да преминем и оттук нататък не можем повече да подобряваме модела.

За всеки модел ние ще предполагаме, че той може и да изпълнява свойството на Марков, но че е по-вероятно да не го изпълнява. Тоест ще предполагаме, че за този свят това може и да е най-добрият възможен модел, но по-вероятно е да има и по-добри модели.

2.9.9.2 *Partially observable Markov decision process*

Това ще е следващият модел, който ще разгледаме. Топологията отново е проста. Имаме произволен брой състояния и стрелки по всяко действие между всеки две състояния. Имаме вероятности по стрелките, но имаме и вероятности в следата. За всяко състояние на *ED* модела имаме n особености. Във всяко състояние всяко наблюдение ще се появява с някаква вероятност и тази вероятност в общия случай ще е различна от средната.

Въпросът е дали така описаният *Partially observable MDP (POMDP)* има интерпретация. Той може да има, а може и да няма. (Ако това е един неадекватен модел, тогава няма да има интерпретация.) Затова ще разгледаме множеството на възможните интерпретации и за всяка интерпретация ще определим вероятностите по стрелките и в следата.

Ще разгледаме еднозначните интерпретации. Тоест ще разбием множеството S' на класове на еквивалентност (S' е множеството на моментите). Ще съпоставим на всяко състояние на *ED* модела по един клас на еквивалентност при това разбиване.

Забележка: Релацията на еквивалентност R не е съвсем произволна, защото R трябва да запазва прехода по наблюдение. Тоест за всеки нечетен момент $\langle t, L \rangle$ трябва той и следващият момент $\langle t+1, L \rangle$ да бъдат в един и същи клас на еквивалентност. Достатъчно условие за запазването на прехода по наблюдение е да направим R на базата на някоя релация на еквивалентност върху множеството O (множеството на стрелките по наблюдение).

Нека събитията C_i са тези, които определят класовете на еквивалентност на R .

$$p_{iaj} = \text{expected}(C_j(t+2) \mid C_i(t) \ \& \ act(t+1)=a)$$

Тоест следващото състояние е j , при условие че предишното състояние е било i и последното действие е било a .

Каква ще е следата на *POMDP*? За всяко състояние i имаме n възможни наблюдения и всяко от тези наблюдения се случва с някаква вероятност q_{ij} .

$$q_{ij} = \text{expected}(ob(t)=o_j \mid C_i(t))$$

Както казахме, функцията *expected* може да върне фиксирана вероятност или да върне вероятностен интервал. Ако искаме да получим класическата дефиниция на *POMDP*, ще трябва да предположим, че p_{iaj} и q_{ij} са фиксирани вероятности.

Забележка: Ако се ограничим със стандартната дефиниция за *Partially observable MDP*, тогава единствената възможна следа на модела ще са вероятностите q_{ij} . Ние обаче ще предположим, че може да има и други следи, т.е. други особености на състоянието S_i . Например може в това състояние определено действие да не може да се случи. Друга възможност за следа е определена конюнкция от събития да е невъзможна, макар събитията от конюнкцията поотделно да са възможни.

Забележка: Изниква въпросът дали светът има съвършен *Partially observable MDP* (такъв, който изпълнява свойството на Марков). Имаме много различни *POMDP* (например за всяка релация на еквивалентност над O имаме такъв модел). Въпросът е има ли измежду всичките тези модели един, който да е съвършен. Отговорът е: „Да, има“. Този модел ще получим, ако вземем всички стрелки от O и за всяка стрелка направим събитието „минавам по тази стрелка“. Това събитие ще е истина във всеки нечетен момент, в който тръгваме по стрелката, както и в следващия момент. Така полученият *POMDP* ще е съвършен и това следва от съвършенството на базовия модел. Този модел няма да е минимален, но ако обединим стрелките, които са с едно и също начало и един и същи край, тогава ще получим *POMDP*, който ще е съвършен и минимален (това следва от съвършенството и минималността на базовия модел).

2.9.10 Литературен обзор

Идеята за създаването на *ED* моделите е, че състоянията на света са твърде много и е добре да ги намалим, за да направим модела по-разбираем. Същата идея е залегнала и в Wang, Joshi and Khaldon (2008). Там се въвеждат *Relational MDP*, които по същество са частен случай на *ED* моделите.

Казахме, че всяка релация на еквивалентност (която разбива множеството на стрелките) може да послужи за създаването на *POMDP*. Идеята за *Relational MDP* е да се изберат някои събития. (Вместо за събития, те говорят за *predicates*, *actions* и *rewards*.) Чрез тези събития се дефинира релация на еквивалентност (две състояния са еквивалентни, ако в тях се случват едни и същи събития от избраните). Върху фактор множеството на тази релация се дефинира *POMDP* и това е търсеният *Relational MDP*.

Забележка: При дефиницията в Wang et al. (2008) не се използва фактор множество, а се говори за семейство от *MDPs*. Ако всеки един от тези *MDPs* има само по едно състояние от всеки един от класовете на еквивалентност, тогава той ще има структурата на фактор множеството, но в общия случай това не е така. Затова по-добре е *Relational MDP* да се дефинират чрез фактор множеството.

Как изглежда *Relational MDP*? Ще разгледаме три случая:

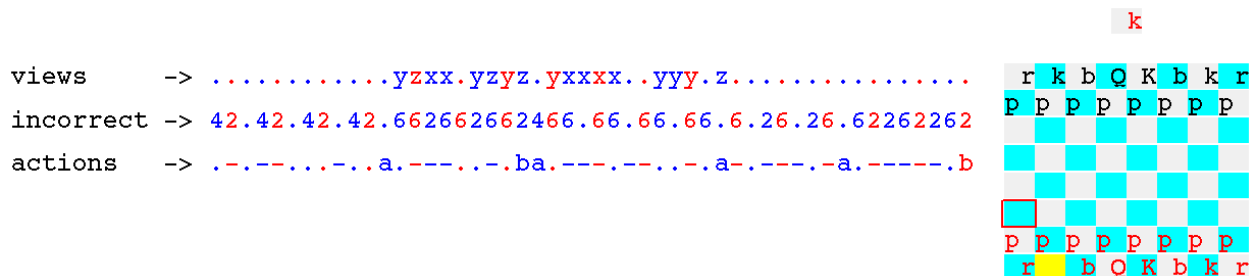
1. Нека входът да се състои от 10 бита. Нека тези 10 бита да бъдат десетте събития, които са избрани, и чрез тях да е направен *Relational MDP*. Тогава този *Relational MDP* съвпада с *FOMDP*.
2. Нека сега само 5 от тези 10 бита да са избрани. Тогава ще получим *Relational MDP* с по-малко състояния от *FOMDP*.
3. Нека сега са избрани десетте бита на входа и още пет събития, които са невидими (не следват от стойността на входа). Нека с тези 15 събития да направим *Relational MDP*. Сега полученият *Relational MDP* ще има повече състояния от *FOMDP*.

2.10 Описание на играта шах

2.10.1 Компютърна емуляция

Светът на играта шах сме емулирали с компютърната програма (Dobrev, 2020a), която е написана на езика (Dobrev, 2020b). Тази програма използва правилата на играта, които са представени като *ED* модели.

Когато стартирате програмата (Dobrev, 2020a), в долната част на екрана ще видите това, което е изобразено на фигура 4.



Фигура 4

В лявата част се вижда потокът входно-изходна информация. Това не е целият поток, а само последните 50 стъпки. На първия ред са наблюденията на агента, а на третия ред са действията му. Възможните наблюдения са четири {0, x, y, z}. Възможните действия също са четири {0, a, b, c}. За по-добра четливост нулата и символът „с“ са заменени с точка и с минус. На втория ред се вижда кои действия са позволени в конкретния момент (2 означава, че действието *a* е некоректно, 4 означава, че *b* е некоректно, 6 означава, че и *a*, и *b* са некоректни).

Това, което е в лявата част на фигура 4, е това, което вижда агентът. Това, което е в дясната част на фигурата, агентът не го вижда, но трябва да си го представи, за да разбере света. Вдясно се вижда позицията на табло, вижда се коя фигура агентът е вдигнал (коня), вижда се и откъде я е вдигнал (жълтото квадратче), вижда се и кое е наблюдаваното в момента квадратче (ограденото с червена линия).

2.10.2 Използваме кодиране

Агентът ще може да извършва 8 действия. Той ще може да мести поглед (квадратчето, което наблюдава) в четирите посоки. Ще може да вдигне фигурата, която вижда, и да пусне вдигнатата фигура в квадратчето, което вижда в момента. Седмото и осмото действие е да не прави нищо.

Ще ограничим действията на агента до четири букви – {0, a, b, c}. Символите „0“ и „с“ ще използваме за действията „не върша нищо“. Как с оставащите два символа ще опишем 6 действия? Това ще стане чрез кодиране. Ще разделим стъпките на три. На всяка първа стъпка ще казваме как движим квадратчето по хоризонтала (т.е. как движим прозореца ни на наблюдение). На всяка втора стъпка ще казваме как движим квадратчето по вертикала, а на всяка трета стъпка ще казваме дали вдигаме фигура, или пускаме вдигнатата фигура.

В Dobrev (2013b) споменахме, че трябва да избягваме излишното кодиране, защото светът е достатъчно сложен и няма нужда допълнително да го усложняваме. Тук обаче не става дума за излишно кодиране, защото с това кодиране светът не се усложнява, а става по-прост, защото заменяме осем действия с четири.

2.10.3 Две празни действия

Защо въвеждаме две действия, които означават „не върша нищо“? Всъщност, когато агентът стои и не върши нищо, той наблюдава света. Въпросът е дали той ще е пасивен наблюдател, или ще наблюдава активно?

Когато стоите и наблюдавате света, вие не сте пасивен наблюдател. Най-малкото движите поглед.


Всички зависимости, които може да види пасивният наблюдател, са периодични. В известен смисъл периодичните зависимости са малко и не са особено интересни. Много по-интересни са зависимостите, които може да види активният наблюдател.

Очакваме агентът да може да забележи определени зависимости (свойства). Например видът и цветът на фигурите са такива свойства. Когато агентът седи в едно квадратче и не върши нищо, ще му е трудно да хване зависимостта (свойството), още повече, че може да му се наложи да хваща две или три зависимости едновременно. Ако агентът е активен и може да редува две действия, тогава зависимостите, които наблюдава, ще са много по-ясни и по-бързо откриваеми.

За да различим двете действия „не върша нищо“, второто сме го нарекли „оглеждам“.

2.10.4 Едно, две, три

Първата зависимост, която ще съществува в този конкретен свят (света на играта шах), идва от това, че разделихме стъпките на три. Тази зависимост ще наречем „Едно, две, три“. Моделът на тази зависимост е изобразен на фигура 5.



Фигура 5

Какво представлява тази зависимост? Тя брой: едно, две, три.

Тази зависимост се представя с един *Event-Driven* модел. В конкретния случай това е модел с три състояния. В този модел имаме само едно събитие и това е събитието „винаги“ (тоест „истина“ или „на всяка стъпка“).

2.10.5 Следа

Дали в състоянията на гореописания модел се случва нещо специално, което да можем да забележим и което да ни помогне да открием този модел? Тоест има ли „следа“ (това е терминология, въведена в Dobrev, 2018)?

Да, в третото състояние задължително едно от действията *a* или *b* е некоректно (или и двете). Това е така, защото в третото състояние ние казваме дали вдигаме фигурата,

която виждаме, или пускаме вдигната вече фигура. Няма как тези две действия да са възможни едновременно.

Можем и без тази следа да опишем света, но без нея зависимостта „Едно, две, три“ би била много по-труднооткриваема. Затова е добре, че имаме някаква следа в този модел.

Следата е това специалното, което дава смисъла на модела. Например в хладилника има студена бира и това го прави един по-специален шкаф. Ако във всички шкафове имаше студена бира, тогава хладилникът нямаше да е по-специален и щеше да е все едно кой шкаф ще отворим.

Следата ни дава възможност да предскажем какво ще се случи. Ако отворим хладилника, очакваме вътре да има студена бира. Освен това следата ни помага да познаем в кое състояние сме и да ограничим недетерминираността. Например отваряме бял шкаф, но не знаем дали това е хладилникът, или друг бял шкаф. Ако вътре има студена бира, тогава ще разберем, че сме отворили хладилника и по този начин ще ограничим недетерминираността.


Ще разглеждаме два вида следа – постоянна и подвижна. Постоянна следа ще са специалните неща (явления), които всеки път се случват, а подвижна следа ще са нещата, които се случват временно.

Например да си представим една къща като един *Event-Driven* модел. Състоянията на този модел ще са стаите. Нещо постоянно за стаите ще е броят на вратите. Временни явления, които се явяват и изчезват, са „светла“ и „топла“. Тоест постоянната следа може да ни каже коя стая е преходна, а подвижната следа ще ни каже коя стая в момента е топла.

Стаите могат да са свързани с различни обекти. Тези обекти си имат свойства (явленията, които се наблюдават, когато виждаме съответния обект). Обектите могат да са постоянни или подвижни и съответно техните свойства ще са относително постоянни или временни явления (относително постоянно е явление, което в дадено състояние се явява винаги). Пример за постоянни обекти са мебелите (особено по-тежките). Пример за подвижни обекти са хората и животните. Тоест постоянната следа ще описва това, което е постоянно, а подвижната следа ще описва това, което е временно.

2.10.6 *Horizontal и Vertical*

Следващият *Event-Driven* модел, който ще ни е нужен за описанието на света, е моделът *Horizontal* (фигура 6).




Фигура 6

Този модел ще ни даде отговор на въпроса „В коя колона на шахматната дъска се намира квадратчето, което наблюдаваме?“.

Тук имаме две събития и това са събитията „наляво“ и „надясно“. Тоест агентът мести поглед наляво или надясно. Тоест той извършва действията *a* и *b*, когато моделът 1 е в състоянието 1. Имаме и две следи. В състоянието 1 не може да се играе наляво. Тоест, когато сме в състояние 1, събитието „наляво“ не може да се случи. Аналогично е със състоянието 8 и следата, че там не може да се играе надясно. Тези две следи ще направят моделът откриваем. Например вие, ако сте в тъмна стая, широка 8 стъпки, ще установите, че след седем стъпки наляво по-наляво не може. Ще го установите, защото ще се блъснете в стената. Тоест сблъсъкът със стената е следата в случая. Такъв сблъсък ще има само на първата и на последната позиция.

Тази следа, освен че ще ни помогне да открием модела, ще е полезна още, за да ни обясни света. Как иначе бихте си обяснили защо в най-лявата колона не можете да играете „наляво“?

Съвсем аналогичен на модела *Horizontal* е моделът *Vertical* (фигура 7).



Фигура 7

Този модел ще ни каже в кой ред се намира квадратчето, което наблюдаваме. Аналогично имаме две събития („напред“ и „назад“), както и две следи („не може напред“ и „не може назад“).

Логично е да направим декартовото произведение на горните два модела и да получим модел с 64 състояния, който ще отговаря на шахматното табло.

Лошото е, че в това декартово произведение няма постоянна следа. Тоест нищо специално не се случва в някое от квадратчетата. Случват се разни работи, но те не са постоянни, а временни. Например в едно квадратче може да виждаме бяла пешка и това да е сравнително постоянно, но не е напълно постоянно, защото пешката може да се премести.

Стигаме до извода, че следата може и да не е постоянна.

2.10.7 Подвижна следа

Както казахме, „подвижна следа“ ще са специалните неща, които се случват в едно състояние, но не се случват постоянно, а само временно.

Как да изобразим подвижната следа? Постоянната следа изобразявахме, като отбелязвахме върху състоянието дали някакво събитие винаги се случва в това състояние (винаги отбелязваме с червено, а със синьо отбелязваме, когато никога не се случва).

Подвижната следа ще изобразим като масив, който има толкова клетки, колкото състояния има съответният модел. Във всяка клетка ще запишем подвижните следи, които в момента са в съответното състояние. Тоест масивът на подвижната следа ще мени стойностите си.


Ето как ще изглежда масивът на подвижната следа на декартовото произведение на втория и третия модел:

8	black rook unmov	black knight unmov	black bishop unmov	black queen unmov	black king unmov	black bishop unmov	black knight unmov	black rook unmov
7	black pawn unmov	black pawn unmov	black pawn unmov	black pawn unmov	black pawn unmov	black pawn unmov	black pawn unmov	black pawn unmov
6								
5								
4								
3								
2	white pawn unmov	white pawn unmov	white pawn unmov	white pawn unmov	white pawn unmov	white pawn unmov	white pawn unmov	white pawn unmov
1	white rook unmov	white lift unmov	white bishop unmov	white queen unmov	white king unmov	white bishop unmov	white knight unmov	white rook unmov
	1	2	3	4	5	6	7	8

Фигура 8

Тази подвижна следа е много сложна, защото това е подвижната следа на модел с 64 състояния. Нека да вземем подвижната следа на модел с две състояния (фигура 9). Това е моделът 4, който помни дали сме вдигнали фигура. Неговата подвижна следа ще помни коя е вдигнатата фигура. Разбира се, този модел, освен подвижна следа, си има и постоянна, която казва, че в състоянието 2 не може „нагоре“, докато в състоянието 1 не може „надолу“.

Подвижната следа на този модел представлява масив с две клетки, които съответстват на двете състояния на *ED* модела. Клетката, която съответства на текущото състояние, е отбелязана, като е оградена с червена линия. Не е толкова важно какво има в клетката, съответстваща на текущото състояние, а това, което е в другите клетки, защото те ни казват какво ще се случи, когато някоя от другите клетки стане текуща. В случая, ако пуснем вдигната фигура, ще отидем в състоянието 1 и там ще видим вдигната фигура. (Ще видим това, което сме пуснали. В случая ще видим „бял кон“.)



Фигура 9

Езикът за описание на светове трябва да ни каже кое е текущото състояние на света. Къде се записва това състояние? Записва се на две места. Първо, това е текущото състояние на всеки от *ED* моделите и, второ, това е подвижната следа. Например на фигура 8 виждате как чрез подвижната следа се представя позицията на шахматната дъска.

Ако езикът за описание на светове беше стандартен език за програмиране, неговата памет щеше да е стойността на променливите и на масивите. Тук можем да направим аналогията, че текущото състояние на един *ED* модел е стойността на една променлива, а стойността на една подвижна следа е стойността на един масив.

Стойността на текущото състояние на един *ED* модел обикновено е едно число, ако моделът е детерминиран, но може да е няколко числа, ако *ED* моделът има няколко текущи състояния (стойността може да е *belief*, ако различните състояния си имат различна вероятност). Стойността на всяка от клетките на подвижната следа ще се състои от няколко числа, защото в едно състояние може да има много подвижни следи. Разбира се, постоянните следи също може да са повече от една.

2.11 Алгоритми

След като описахме основните правила на играта шах и позицията на таблото, следващата стъпка е да кажем как се движат фигурите. За целта ни е нужно понятието „алгоритъм“.

Обикновено в литературата не се прави разлика между алгоритъм и изчислима функция. Това не е правилно, защото алгоритъмът е действие, а изчислимата функция е резултатът от това действие. Трябва да правим разлика между действие и резултат. Например приготвянето на палачинки е нещо различно от палачинките. Резултатът от алгоритъма зависи от това в кой свят го изпълняваме. Например алгоритъмът за

приготвяне на палачинки в друг свят може да даде друг резултат. Този друг резултат може да бъде например изчислима функция или космическа ракета.

2.11.1 Какво е алгоритъм?

За повечето хора алгоритъмът е машина на Тюринг. Това е така, защото те разглеждат само функциите от \mathbb{N} в \mathbb{N} и за тях алгоритъм е нещо, което изчислява такава функция. За нас алгоритъмът ще описва последователност от действия в произволен свят. Например за нас алгоритми ще са готварските рецепти, танцовите стъпки, умението да се хване топка и т.н. Казахме „последователност от действия“. Нека се коригираме и да стане „последователност от събития“. Действието е събитие, но не всяко събитие е действие или поне не е наше действие, а може да е действие на някой друг агент. В описанието на алгоритъма освен наши действия ще има и други събития. Например чакаме, докато водата кипне. Кипването на водата е събитие, което не е наше действие.

При нашата дефиниция алгоритъмът може да се осъществи въобще без нашето участие. Да вземем като пример „Лунната соната“. Това е алгоритъм, който ще изпълним, ако изсвирим „Лунната соната“, но ако я изсвири някой друг, тогава това пак ще е алгоритъм, но изпълнен от някой друг. Ако разпознаем „Лунната соната“, ние ще сме разпознали този алгоритъм, нищо че не го изпълняваме.

Няма да е много важно кой изпълнява алгоритъма. Нормално е един алгоритъм първо да ни бъде показан от някой друг, после да го изпълним и ние.

Ще разгледаме три варианта на алгоритъм:

1. релсов път;
2. планинска пътека;
3. отивам си вкъщи.

При първия вариант ще предполагаме, че имаме ограничения, които не ни позволяват да се отклоним от изпълнението на алгоритъма. Например, когато се качим на автобуса, ние пътуваме по маршрута и не можем да се отклоним, защото друг кара автобуса. Когато слушаме „Лунната соната“, отново нищо не можем да променим, защото не свирим ние.

При втория вариант ние можем да се отклоним, но има последствия, ако се отклоним. Планинската пътека минава покрай пропаст. Ако се отклоним, ще паднем в пропастта.

При третия вариант можем да се отклоним от пътя. След отклонението можем отново да се върнем в пътя, а може и да минем по друг път. Алгоритъмът за прибиране у дома ни казва, че ако го изпълним, ще сме си вкъщи, но по никакъв начин не сме задължени да го изпълним или да го изпълним точно по този начин.

Обикновено, когато говорим за алгоритъм, предполагаме детерминираност. Представяме си компютърна програма, при която за всеки следващ момент се знае точно кое ще е действието, което ще бъде извършено. Вече дори и компютърните програми не са еднонишкови. При многонишковите програми не е съвсем ясно кое ще е следващото действие, което ще бъде извършено. Още по-ясен е примерът с готварските рецепти. Когато правим палачинки, не е казано дали първо да сложим яйцата и после млякото, или обратното. И в двата случая ще изпълним един и същ алгоритъм.

Представете си алгоритъма като движение в пещера. Можете да вървите напред, но можете да се върнете и назад. Галерията има разклонения и вие имате избор накъде да

завиете. Само ако излезете от пещерата, ще сте прекратили изпълнението на алгоритъма „движи се в пещерата“. Тоест ще си представяме алгоритъма като ориентиран граф с много разклонения, а не като път без разклонения.

2.11.2 Алгоритъмът на фигурите

С алгоритмите ще опишем движението на фигурите. Ние ще изберем варианта „релсов път“ (първия от разгледаните варианти). Тоест, когато вдигнете фигура, ще се включва съответният алгоритъм, който няма да ви позволи да направите грешен ход.

Можеше да изберем и варианта „планинска пътека“. Тоест да може да се отклоните от алгоритъма, но това да е с последствия. Например вдигате фигурата и започвате да изпълнявате алгоритъма, но ако го нарушите, ще изпуснете вдигната фигура и тя ще се върне на мястото си.

Можеше да изберем и варианта „отивам си вкъщи“. При този вариант се движите както пожелаете, но можете да поставите фигурата само на тези места, където алгоритъмът би могъл да я постави, ако беше изпълнен. Тоест имате пълна свобода на движението, а алгоритъмът само ви дефинира кои ходове са коректните.


Ще изберем първия вариант, главно защото сме пуснали агента да играе случайно и ако не го вкараме в релси, за него ще е много трудно да изиграе коректен ход. Освен това трябва да си помислим как агентът ще разбере света. Как ще открие тези алгоритми? Ако го вкараме в релси, той ще научи алгоритъма по неволя, но ако го оставим свободно да се движи, за него ще е много трудно да отгатне какви са тези правила на движение (какви са тези алгоритми). Например, ако покажете на един ученик алгоритъма за намиране на корен квадратен, то на него ще му е сравнително лесно да го научи. Много по-трудно би му било, ако му обясните какво е корен квадратен и го оставите сам да намери алгоритъма за изчисляването му. Можете да покажете на ученика какво е корен квадратен с дефиниция или с примери, но по-лесно ще ви разбере, ако му покажете директно алгоритъма.

Какво ще представляват алгоритмите? Това ще са *Event-Driven* модели. Ще има някакво събитие, което ще е вход и което ще стартира алгоритъма, и още някакво събитие, което ще е изход и след което алгоритъмът ще престане да се изпълнява. По-нататък ще направим изходите да са два (успешен и неуспешен изход).

Всяка фигура ще си има алгоритъм.

2.11.3 Алгоритмите на царя и на коня

Най-простият алгоритъм ще бъде алгоритъмът на царя (фигура 10). Входящото събитие ще бъде „вдигам фигурата цар“. Входящата точка ще бъде състоянието 1 (при всичките алгоритми това ще бъде входящата точка). Събитията ще са 4 (наляво, надясно, напред и назад).




Фигура 10

Следата ще се състои от четири събития (не може наляво, не може надясно и т.н.) Тези четири събития (следи) ще ограничат движението до девет квадратчета. Тези 4 събития (следи) ще са релсите, в които ще влезем и които няма да ни позволят да напуснем деветте квадратчета, докато изпълняваме алгоритъма. На фигура 10 четирите следи са отбелязани с червени хоризонтални линии. Например горните три състояния имат първата следа, което значи, че от тези три състояния не може напред.

Ще можем да пуснем вдигната фигура (царя) във всеки момент, когато пожелаем. Разбира се, може да има други правила или алгоритми, които да ни ограничават. Например не можем да вземем собствена фигура, тоест има и други ограничения, но те не идват от този алгоритъм. Ако пуснем фигурата в състоянието 1, тогава ходът ни няма да е истински, а ще е фалшив. Ако пуснем фигурата в някое от другите състояния, тогава ще сме изиграли един истински ход.


Малко по-сложен е алгоритъмът на коня (фигура 11). Основната разлика с алгоритъма на царя е, че тук има още една следа. Тази следа ни ограничава и в някои от състоянията няма да можем да спускаме вдигната фигура. (Тази следа е отбелязана на фигура 11, а другите 4 следи не са отбелязани.) Спазвайки този алгоритъм, ние имаме само две възможности. Първата е да изиграем коректен ход с коня, а втората е да изиграем фалшив ход, като върнем коня там, откъдето сме го взели.



Фигура 11


2.11.4 Алгоритмите на топа и на офицера

Макар че има малко състояния, алгоритъмът на топа е по-сложен (фигура 12). Причината за това е, че този алгоритъм е недетерминиран. Например в състоянието 3, когато играем „напред“, тогава има две стрелки, които отговарят на това събитие. Съответно има две състояния, които могат да са следващите. Тази недетерминираност веднага се разрешава, защото в състоянието 1 задължително трябва да се вижда, че от това квадратче е вдигната фигура, докато в състоянието 3 задължително това не трябва да се вижда. Тоест имаме следа, която веднага разрешава тази недетерминираност.



Фигура 12

Алгоритъмът на офицера е още по-сложен (фигура 13). Основната причина за това е, че не можем да се придвижим директно по диагонала, а за целта трябва да направим две стъпки (първата по хоризонтала и втората по вертикала). Когато в състоянието 1 се случи събитието „наляво“, тогава ние не знаем дали сме тръгнали по диагонала „наляво и напред“, или по диагонала „наляво и назад“. Тогава се получава недетерминираност, която не може да бъде разрешена незабавно. Все пак тази недетерминираност ще се разреши, когато дойде едно от събитията „напред“ или „назад“. В двете възможни състояния имаме следи, които ни казват, че в състояние 8 не може „напред“, а в състояние 2 не може „назад“. Ако и в двете състояния не можеше „напред“, то тогава събитието „напред“ би нарушило алгоритъма. В случая в едното състояние може, а в другото не може. Тоест събитието „напред“ е разрешено, но когато то се случи, състоянието 8 ще престане да бъде активно и недетерминираността ще се разреши. (На фигура 13 сме отбелязали само следите „не може напред“ и „не може назад“.)



Фигура 13

Най-сложен е алгоритъмът на царицата, защото той е съчетание от алгоритмите на топа и на офицера. Алгоритъмът на пешката не е сложен, но имаме четири такива алгоритъма, защото имаме различни алгоритми за бяла и за черна пешка, както и за преместена и за непреместена пешка.

2.11.5 Машината на Тюринг

Описахме алгоритмите на движение на шахматните фигури като *Event-Driven* модели. Можем ли да приемем, че всеки алгоритъм може да се представи като *Event-Driven* модел? Дали машината на Тюринг може да се представи по този начин?

Ще опишем един свят, който представлява машина на Тюринг. Първото нещо, което трябва да опишем в този свят, е безкрайната лента. В играта шах описахме шахматното табло като подвижната следа на някакъв *Event-Driven* модел с 64 състояния. Тук отново ще използваме подвижната следа, но ще ни е нужен модел с изброимо много състояния. Да вземем модела от фигура 6. Това е модел на лента с осем клетки. Трябва ни същият модел, пак да има две събития (наляво и надясно), но да не е ограничен отляво и отдясно. Получава се *Event-Driven* модел с безкрайно много състояния. Досега използвахме *ED* модели само с крайно много състояния. Сега ще ни се наложи да добавим и някои безкрайни *ED* модели, но които имат проста структура като този. В случая моделът представлява просто един брояч, който помни едно цяло число (т.е. елемент на \mathbb{Z}). Броячът има две операции (минус едно и плюс едно) или (наляво и надясно). Добавянето на този безкраен брояч разширява езика, но, както казахме, ние ще разширяваме езика, за да покрием световите, които искаме да опишем.

Каква ще е паметта на този свят? Трябва да запомним стойността на брояча (коя клетка от лентата гледа главата на машината). Това е произволно цяло число. Освен това ще трябва да запомним и какво има записано върху лентата. За целта ще ни трябва безкрайна последователност от нули и единици, което е равномошно на континуум. Обикновено използваме машините на Тюринг, за да изчисляваме функции от \mathbb{N} в \mathbb{N} . В този случай бихме могли да се ограничим само с конфигурации, при които е използвана само крайна част от лентата, тоест бихме могли да се ограничим само с изброимо много конфигурации, но всички възможни конфигурации на лентата са континуум много.

Забележка: представата на агента за състоянието на света ще е изброима, дори ако паметта на света е континуум. Казано по друг начин, агентът няма как да си представи всички възможни конфигурации върху лентата, а само изброима част от тези конфигурации. При горното разсъждение използваме това, че си мислим агента като абстрактна машина с безкрайна памет. Ако агентът си го мислим като реален компютър с крайна памет, тогава в горното разсъждение трябва да заменим „изброима“ с „крайна“. Все пак, ако агентът е програма на реален компютър, то тази крайна памет е толкова голяма, че за по-просто ще си я мислим за изброима.

Описахме безкрайната лента на машината на Тюринг с един безкраен *ED* модел. За да опишем главата на машината (самия алгоритъм), ще ни трябва още един *ED* модел. Вторият *ED* модел ще построим, използвайки машината на Тюринг.

Предположихме, че машината използва две букви $\{0, 1\}$. Ще направим *Event-Driven* модел с четири събития:

- *write(0)*,
- *write(1)*,
- *move left*,
- *move right*.


Тогава всяка от командите на машината ще изглежда така:

- if *observe(0)* then *write(Symbol_0)*, *move Direction_0*, go to *Command_0*
- if *observe(1)* then *write(Symbol_1)*, *move Direction_1*, go to *Command_1*

Тук $Symbol_i$, $Direction_i$ и $Command_i$ са заменени с конкретни стойности. Например:

- if $observe(0)$ then $write(1)$, move left, go to s_3
- if $observe(1)$ then $write(0)$, move right, go to s_7

Всяка команда ще заменим с четири състояния, които ще я опишат. Горната команда ще изглежда така:



Фигура 14

На фигура 14 входът е по събитието *move right*. Всъщност ще се влиза от много места, понякога по събитието *move left*, а понякога по събитието *move right*. Важното е, че входът ще е недетерминиран, но веднага тази недетерминираност ще се разреши, защото първите две състояния имат следа. В горното задължително трябва да се случи събитието $observe(0)$, а в долното задължително това събитие не трябва да се случва.

Тоест всяко от състоянията на автомата се заменя с четири състояния, както е показано на фигура 14, след това отделните четворки се свързват помежду си. Например четворката от фигура 14 се свързва с четворката, съответстваща на s_3 , чрез стрелки по събитието *move left* и с четворката, съответстваща на s_7 , чрез стрелки по събитието *move right*.

Трябва да добавим още малко следа. За всяко едно от състоянията е възможно само едно от четирите събития. Трябва да добавим като следа, че другите три събития са невъзможни. Това е, ако искаме алгоритъмът да е от тип „релсов път“. Ако предпочитаме да е от тип „планинска пътека“, трябва да добавим следа, която да казва че ако се случи някое от другите три събития, ще настъпят съответните последствия. Ако искаме типът да е „отивам си вкъщи“, тогава другите три събития трябва да водят до прекратяване на алгоритъма.

По този начин представихме машината на Тюринг с *Event-Driven* модел. По-точно с два *ED* модела – първия с безкрайно много състояния и втория с краен брой (четири пъти повече от състоянията на машината).

Кой изпълнява алгоритъма на машината на Тюринг? Може да предположим, че четирите събития са действия на агента и че той е този, който изпълнява алгоритъма. Може да предположим, че тези събития ги изпълнява друг агент или че те просто се случват. Тогава агентът не изпълнява алгоритъма, а е само наблюдател. В общия случай, една част от събитията на алгоритъма ще са действия на агента, а останалата част няма да са. Например „сипвам вода“ е действие на агента, а „водата завира“ не е негово действие. Агентът може да влияе и на събитията, които не са негови действия. Това е описано в Dobrev (2021b). Спрямо тези събития той може да има някакво „предпочитание“ и чрез това „предпочитание“ той би могъл да влияе на това дали тези събития ще се случат.

2.11.6 Литературен обзор

Важно е, че в тази дисертация е дефинирано понятието „алгоритъм“. Много малко са хората, които въобще си задават въпроса какво е алгоритъм. Единствените опити за дефиниция на алгоритъм, които са ми известни, са направени от Moschovakis (2001, 2018). В тези трудове Moschovakis казва, че повечето автори дефинират алгоритъма чрез някаква абстрактна машина и отъждествяват алгоритмите с програмите за тази абстрактна машина. Moschovakis формулира каква дефиниция на алгоритъм ни е необходима. Той иска да създаде едно общо понятие, което да не зависи от конкретната абстрактна машина. Такова понятие е изчислимата функция, но това понятие е твърде общо за Moschovakis и той иска да направи по-специализирано понятие, което да отразява това, че една изчислима функция може да се изчисли от много принципно различни алгоритми. В Moschovakis (2001) не е постигната високата цел, поставена от автора. Това, което той е направил, може да се приеме за една нова абстрактна машина. Наистина тази машина е много интересна и е по-абстрактна от повечето известни машини, но отново имаме недостатъка, че програмата на машината може безсмислено да се усложни, като се получи друга програма, реализираща същия алгоритъм. Макар че в Moschovakis (2001) не се постига целта да бъде създадена обща дефиниция на алгоритъм, самият Moschovakis казва, че за него по-важното е да постави въпроса, дори и да не успее да му отговори. Точните думи на Moschovakis са: „my chief goal is to convince the reader that the problem of founding the theory of algorithms is important, and that it is ripe for solution“.

2.12 Обекти

2.12.1 Свойства

След понятието „алгоритъм“ ще се опитаме да дефинираме още едно фундаментално понятие. Това ще е понятието „свойство“. За дефиницията на това понятие отново ще използваме *Event-Driven* модели. Свойствата са явленията, които се случват, когато се наблюдава обект със съответното свойство. Явленията са зависимости, които не се наблюдават постоянно, а само от време на време. Щом другите зависимости се представят с *Event-Driven* модели, естествено е и свойствата да се представят по същия начин.

Разликата между зависимост и свойство ще бъде, че зависимостта ще е активна постоянно (т.е. ще се наблюдава постоянно), докато свойството ще се наблюдава понякога (когато наблюдаваме съответния обект).

2.12.2 Какво е обект

Базовото понятие ще е свойство, а обектът ще е абстракция от по-висок ранг. Например, ако в света на играта шах се наблюдават свойствата „бял“ и „кон“, може да се направи изводът, че има обект „бял кон“, който се наблюдава и който има тези две свойства. Може и да не стигаме до тази абстракция и да си мислим, че просто някакви свойства се местят. Тоест че някакви явления се появяват и изчезват.

2.12.3 Второ кодиране


Изходът на агента се състои само от четири букви и затова използвахме кодиране, за да представим осемте възможни действия на агента. Входът също е ограничен до четири букви. Вярно е, че входът трябва да ни даде информация само за едно от квадратчетата, а не за цялото табло. Въпреки това четири букви са твърде малко, защото в квадратчето може да има шест различни фигури с два различни цвята. Освен това ни трябва

допълнителна информация като това дали пешката е местена и дали от този квадрат не е вдигнатата фигура. Как да представим всичката тази информация с четири букви?

Тази информация не е задължително да идва до агента само за една стъпка. Той може да постои известно време върху квадратчето и да наблюдава входа. Той може да забележи различни зависимости, докато наблюдава квадратчето. Наличието или отсъствието на всяка от тези зависимости ще е информацията, която ще получи агентът за квадратчето, което наблюдава. Макар буквите на входа да са само четири, зависимостите, които могат да се опишат с четири букви, са безбройно много.

Тези зависимости ще наречем „свойства“ и ще предполагаме, че агентът може да разпознава (да хваща) тези зависимости. Ще предполагаме още, че той може да хване няколко зависимости, дори когато те са една върху друга. Например агентът трябва да може да хване свойствата „бял“ и „кон“, дори когато те се проявяват едновременно.

Как изглеждат свойствата? Зависимостите и алгоритмите за движение на фигурите са написани от човек, който има идея какви са правилата на играта шах и как се движат фигурите. Свойствата не са написани от човек, а са генерирани автоматично. Например на фигура 15 е изобразено свойството „пешка“. Това свойство изглежда доста странно и нелогично. Това е така, защото, както казахме, то е генерирано автоматично по случаен начин. Това свойство не е написано от нас, защото ние не знаем как би изглеждала пешката. Не е важно как изглежда тя. Важното е пешката да изглежда по някакъв начин и да може тя да бъде разпозната от агента. Тоест пешката трябва да си има лице, но не е важно как ще изглежда нейното лице.



Фигура 15

В нашата програма (Dobrev, 2020a) има 10 свойства и всяко едно от тях си има някаква следа. Когато няколко свойства са активни едновременно, тогава всяко едно от тях влияе (чрез следата си) на входа на агента. Понякога тези влияния могат да бъдат противоречиви. Например, едно свойство ни казва, че следващият вход трябва да е буквата *x*, а друго свойство ни казва обратното (че не трябва да е *x*). Тогава въпросът се решава с гласуване. Светът брои колко гласа има за всяко решение и избира решението, което е събрало най-много гласове. Що се отнася до противоречивите препоръки, те взаимно се обезсилват.

2.13 Шах с двама играчи

Ще усложним света на играта шах, като добавим още един агент. Това ще е противникът, който играе с черните фигури. Това ще доведе до недетерминираност, защото няма да можем да кажем точно как ще играе противникът. Дори противникът да е детерминиран, тази детерминираност може да е прекалено сложна и да не можем да я опишем.

2.13.1 Детерминиран свят

Описахме света на играта шах, където агентът играе сам срещу себе си. Написали сме програмата (Dobrev, 2020a), която съдържа просто описание на този свят и чрез това описание го емулира. Можете да стартирате тази програма и да видите колко просто се е получило описанието на този свят (на играта шах). Описанието се състои от 24 модула, които представляват *Event-Driven* модели (това са ориентирани графи с по десетина състояния всеки). *ED* моделите са три вида (5 зависимости, 9 алгоритъма и 10 свойства, което прави общо 24). Освен *ED* моделите имаме още две подвижни следи (т.е. два масива). Освен 24-те модула и двата масива ни се е наложило да добавим още седем прости правила, които допълнително описват света. Тези правила ни дават допълнителна информация за това как се променя състоянието на света. Например първото от тези правила ни казва, че ако вдигнем фигура, на нейното място ще се появи свойството *Lifted*. Правилото изглежда така:

up, here \Rightarrow copy(Lifted)

Ако вдигнем фигура и ако сме в квадратчето $\langle X, Y \rangle$, тогава свойството *Lifted* ще замести свойствата, които са в същото това квадратче в момента.

Тези правила ние можем да формулираме благодарение на това, че вече имаме контекста на шахматната дъска (подвижната следа от фигура 8). Ако не знаехме за съществуването на тази дъска, нямаше как да формулираме правила за поведението на фигурите върху дъската. В демонстрационната програма (Dobrev, 2020a) агентът играе случайно. Разбира се, действията на агента не са интересни. Интересното е светът и това, че ние сме го описали.

Описанието, което получихме, е детерминирано. Тоест началното състояние е определено и всяко следващо състояние е определено. Детерминирано описание означава, че в описания свят няма случайност. Трябва ли описанието на света да е детерминирано? Да се ограничим ли само с такива описания? Въобще не е сигурно, че светът е детерминиран, а дори и да е такъв, не е нужно да се ограничаваме само с детерминирани описания.

Ако опишем недетерминиран свят с детерминистично описание, то много скоро това описание ще покаже своето несъвършенство. Обратното, светът може да е детерминиран, но тази детерминираност да е твърде сложна и да не можем да я разберем (да я опишем). Затова може вместо детерминистично описание на света да намерим едно недетерминистично, което да работи достатъчно добре.

Обикновено светът е недетерминиран. Когато стреляме по мишена, може да не уцелим. Това означава, че не всяко наше действие води до резултат и че резултатите понякога могат да бъдат различни.

Ще допускаме, че моделът може да е недетерминиран. Повечето автори, когато говорят за недетерминираност, предполагат, че всяко възможно събитие има точно определена вероятност. В Dobrev (2018) и в Dobrev (2021b) показахме, че последното е твърде детерминирано. Би било твърде силно изискването за всяко събитие да можем да кажем точната вероятност, с която то ще се случи. Затова ще предполагаме, че не знаем точната вероятност, а знаем само интервала $[a, b]$, в който е тази вероятност. Обикновено интервалът ще е $[0, 1]$ и тогава няма да имаме никаква идея с каква вероятност ще се случи събитието.

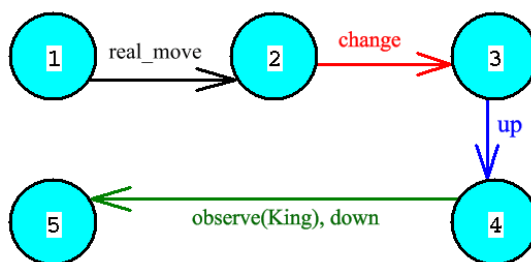
2.13.2 Невъзможни събития

Казахме, че светът би бил по-интересен, ако не играем сами срещу себе си, а ако има още един агент, който да мести черните фигури.

За целта ще променим петия *Event-Driven* модел (този, който ни казва дали играем с белите или с черните фигури). Този модел има две състояния, които се превключват от събитието *change*. Това събитие беше дефинирано като събитието *real_move* (това е, когато играем реален ход, а *fake_move* е, когато само докосваме някоя фигура). Ще променим дефиницията на това събитие и ще го дефинираме като *never* (това е обратното на *every time*). Чрез тази промяна получаваме свят, в който агентът не може да смени цвета си.

Има ли смисъл в модела да описваме събития, които няма как да се случат? Отговорът е, че има смисъл, защото тези събития може да се случват мислено. Тоест тези събития са ни нужни, за да разберем света, макар че те не се случват. Например ние не можем да летим и да си сменим пола, но мислено можем да го направим. Примерът не е много добър, защото ние вече можем да летим и да си сменим пола. Тоест ние може да си мислим за невъзможни събития, освен това в един момент тези събития може от невъзможни да станат възможни.

Ще използваме невъзможното събитие *change*, за да добавим правилото, че нямаме право да играем ход, след който ще сме шах (след който могат да ни вземат царя). На фигура 16 е изобразен алгоритъмът, който описва как сменяме (обръщаме дъската) и вземаме царя. Ако съществува изпълнение на този алгоритъм, тогава ходът не е коректен. (Дори да съществува изпълнение, алгоритъмът не може да бъде изпълнен, защото съдържа невъзможно събитие.)



Фигура 16

Този алгоритъм в по-голяма степен отговаря на представата ни за това как изглеждат алгоритмите. Докато алгоритмите на фигурите представляваха ориентирани графи с много разклонения, този алгоритъм представлява само един път без разклонения. Тоест този алгоритъм е просто една последователност от действия без разклонения.

Този алгоритъм се нуждае от още някои ограничения (следи), които не сме отбелязали на фигура 16. Например в състоянието 1 не можем да се движим в никоя от четирите посоки (иначе бихме могли да се преместим и да изиграем друг ход). Събитието *change* не може да се случва в никое от състоянията освен състоянието 2. В състоянието 4 имаме ограничението *not observe(King) => not down*. Това последното означава, че единственият ход, който можем да направим, е да вземем цар.

В този алгоритъм участва невъзможното действие *change*. Както казахме, това действие е невъзможно, но можем да го извършим мислено. Това събитие може да участва в дефиницията на алгоритми, които няма да изпълняваме, а за които ще е важно само дали съществува изпълнение.


Забележка: В тази дисертация, когато казваме, че алгоритъм може да бъде изпълнен, имаме предвид, че той може да бъде изпълнен успешно. Това означава, че изпълнението може да завърши в крайно (приемащо) състояние или с изходящо събитие (с успешен изход).

2.13.3 Втори агент

Алгоритъмът от фигура 16 би се опростил, ако допуснем съществуването на втори агент. Идеята е вместо да сменяме цвета на фигурите (да обръщаме дъската), да сменим агента с такъв, който винаги играе с черните фигури. Ще се получи алгоритъм, изпълняван от повече от един агент, но такива алгоритми са естествени. Например „Дадох пари на един човек и той купи нещо с тези пари“. Това е пример за алгоритъм, изпълнен от двама агенти.

По важното е, че ще искаме, когато ние преместим бяла фигура, някой друг (друг агент) да премести черна фигура. В предишния случай си задавахме само въпроса „Възможен ли е определен алгоритъм?“, а тук ще искаме някакъв алгоритъм реално да бъде изпълнен. Не е все едно алгоритъмът да е възможен и той реално да бъде изпълнен. Не е все едно „може ли някой да направи палачинки“ или „жена ви да ви направи палачинки реално“. В единия случай знаете нещо за света, а във втория случай реално ядете палачинки. Когато някой агент реално изпълнява даден алгоритъм, не е все едно кой е агентът, който ще изпълни алгоритъма. Например предполагаме, че жена ви ще направи палачинките по-добре, отколкото вие бихте ги направили.

Ще предполагаме, че след всеки наш *real_move* агентът, който играе с черните фигури, ще изпълни алгоритъма от фигура 17.



Фигура 17

Един алгоритъм не се изпълнява за една стъпка, за това са нужни много стъпки. Тук обаче ще предполагаме, че противникът ще играе с черните фигури веднага (за една стъпка). Хората, когато си мислят, че някой ще направи нещо, обикновено си представят резултата, без да отчитат, че това се извършва в продължение на известно време. Например, когато си мислите: „Днес имам рожден ден и жена ми ще ми направи палачинки“. При това разсъждение вие приемате палачинките за направени, без да отчитате, че това отнема време.

Както казахме, не е все едно кой е агентът, който играе с черните фигури. Много важно е дали ни е съюзник или противник (дали ще ни помага или ще ни пречи). Също така, важно е доколко е умен (защото той може да има някакви намерения, но доколко ще ги осъществи зависи от това доколко е умен). Важно е още какво знае и какво вижда агентът. При играта шах предполагаме, че агентът вижда всичко (цялото табло), но в други светове бихме могли да предположим, че агентът знае и вижда само част от информацията. Може да е важно и къде се намира агентът. Тук предполагаме, че това не е важно. Предполагаме, че където и да се намира агентът, той може да се придвижи до произволно квадратче и да вдигне фигурата, която е там. Бихме могли да предположим, че позицията на агента има значение и че за по-близките фигури е по-вероятно да бъдат преместени, отколкото по-далечните.

2.13.4 Собствено състояние

Тук предположихме, че вторият агент си има собствено състояние на света. Тоест има си собствена позиция $\langle x, y \rangle$ на таблото (квадратчето, което наблюдава). Също така предполагахме, че той играе с черните, за разлика от главния герой, който играе с белите.

Предполагахме, че двамата агенти променят света по един и същи модел, но паметта на модела (състоянието на света) е различна за двамата агенти. Бихме могли да предположим, че двете състояния на света нямат нищо общо, но тогава действията на втория агент по никакъв начин няма да влияят на света на главния герой. Затова ще предположим, че позицията на таблото е обща (т.е. обща е следата от фигура 8). Ще предположим, че всеки агент си има собствени координати и собствен цвят, с който играе (т.е. *Event-Driven* моделите 2, 3 и 5 имат различни активни състояния при двамата агенти). За останалите *ED* модели, както и за следата от фигура 11, също ще предположим, че те са отделни за отделните агенти, макар че нищо не пречи да предположим и обратното.

Ако предпологахме, че двамата агенти споделят едно и също състояние на света, тогава алгоритъмът от фигура 17 щеше да е много по-сложен. Противникът първо щеше да обърне дъската (*change*), после щеше да изиграе своя ход и пак да обърне дъската, за да остави света на главния герой непроменен. Освен това противникът трябваше да се погрижи да се върне на същите координати $\langle x, y \rangle$, от които е тръгнал (това са координатите на главния герой). Би било много неестествено различните агенти да са съвсем еднакви и да се намират на едно и също място. Много по-естествено е предположението, че агентите са различни и че имат различно състояние на света, но че част от състоянието е обща. Например „В момента аз правя палачинки и жена ми прави палачинки“. Може ние да правим едни и същи палачинки, а може моите палачинки да нямат нищо общо с нейните.

Забележка: Не е много точно да казваме, че светът има две различни състояния за двата агента. Светът е един и неговото състояние е едно-единствено. По-точно ще е да кажем, че сме променили света и вече имаме свят с по-сложно състояние. Нека новото множество от състояния да е S'' . Можем да предположим, че $S'' = S \times S$. Въпросите, които са общи за двамата агенти, са си останали непроменени, но другите въпроси са се раздвоили. Например въпросът „Къде съм?“ е заменен от въпросите „Къде е главният герой?“ и „Къде е противникът?“. От модела, при който състоянията са S , сме направили нов модел, при който състоянията са S'' . Разликата между S и S'' е, че състоянията в S описват състоянието на един агент (без да се казва кой е той), докато състоянията в S'' описват състоянието на двата агента. (И в двата случая общото състояние на света също се описва.) Новият модел описва света чрез двата агента и това как те променят състоянието си по първия модел. Въпреки всичко, по-естествено е да си мислим, че светът има различни състояния за двата агента и че тези агенти променят състоянията си по първия модел, който работи само с въпросите, които са само за единия агент.

2.13.5 Неизчислимо правило

Описахме първия свят, в който агентът играеше сам срещу себе си, и направихме програмата (Dobrev, 2020a), която емулира този свят. Програмата (Dobrev, 2020a) представлява модел, който е описание на първия свят. Описахме и втори свят, в който агентът играе срещу някакъв противник. Можем ли да направим емулираща програма и за втория свят?

Във втория свят добавихме твърдение от вида „този алгоритъм може да бъде изпълнен“. (Това твърдение трябваше да добавим още в първия свят, защото и там не е

позволено да се играе ход, ако след хода сме шах. За момента програмата (Dobrev, 2020a) позволява да играем такива ходове.) Във втория свят добавихме и операция от вида „противникът изпълнява алгоритъм“. Това твърдение и тази операция в общия случай са неразрешими (по-точно те са полуразрешими).

Да вземем например твърдението „този алгоритъм може да бъде изпълнен“. В конкретния случай става дума за това дали противникът може да ни вземе царя и това е напълно разрешимо, защото шахматната дъска е крайна и има крайно много позиции и всички алгоритми, работещи над шахматната дъска, са разрешими. В общия случай алгоритъмът може да бъде машина на Тюринг и тогава това твърдение е равносилно на стоп проблема (*halting problem*).

Същото може да се каже и за операцията „противникът изпълнява алгоритъм“. Алгоритъмът може да се изпълни по много различни начини, но задачата да намерим поне един от тези начини е полуразрешима. В конкретния случай, когато имаме играта шах, лесно можем да намерим един от начините, по които се изпълнява алгоритъмът. Тук дори можем да намерим всички начини (това са всички възможни ходове), но в общия случай тази задача е полуразрешима.

Тоест в конкретния случай ние можем да напишем програма, която емулира този втори свят. Само трябва да изберем поведението на противника, защото за това поведение има много възможности. С други думи, за да създадем програма, която да емулира света на играта шах, трябва вътре в нея да вградим програма, емулираща шахматен играч.

В общия случай обаче ние няма да можем да напишем програма, емулираща описания от нас свят. Тоест езикът за описание на светове вече описва такива светове, които няма как да бъдат емулирани с компютърна програма. Още в началото казахме, че моделът може да се получи неизчислим. Няма как да напишем програма, която да изчислява неизчислим модел.

Това, че не можем да напишем програма, емулираща описания от нас свят, не е голям проблем, защото нашата цел не е да емулираме света, а да напишем програмата ИИ, която на базата на това, че е разбрала света (намерила е описанието му), ще планира успешно бъдещите си ходове. Разбира се, ИИ би могла да процедира, като направи една емуляция на света и разиграе няколко от възможните бъдещи развития, като избере това, което е най-доброто. (По същество така работи алгоритъмът *Min-Max*, с който шахматните програми играят.) Тоест, ако можем да направим емуляция на света, няма да е лошо, макар и да не е задължително.

ИИ не само, че няма да може да направи пълна емуляция на света (когато моделът е неизчислим), но дори ИИ може да не разбере кое точно е текущото състояние на света (когато възможните състояния са континуум много). Въпреки това ИИ ще може да направи частична емуляция и да разбере състоянието на света частично. Например, ако в света има безкрайна лента и върху нея има безкрайно много информация, тогава няма как ИИ да разбере текущото състояние на света, но може да опише някаква крайна част от лентата и информацията върху тази крайна част.

Дори и *Min-Max* алгоритъмът не е пълна емуляция, заради комбинаторната експлозия. Вместо това *Min-Max* прави частична емуляция, като обхожда само първите няколко хода. Когато в описанието на света има полуразрешимо правило, тогава ИИ ще използва това правило само в едната посока. Например правилото „Ако съществува доказателство, тогава твърдението е вярно“. Хората използват това правило, когато има

доказателство и когато те са го намерили. Когато няма доказателство, тогава това правило не се използва, защото няма как да разберем, че доказателство действително няма.

2.14 Агенти

Следващата абстракция, това е агентът. Също като обектите, агентите няма да можем да ги засечем директно. Тях ще ги наблюдаваме индиректно чрез техните действия. Откриването на агенти е трудна задача. Хората успяват да открият агенти, но за целта те ги търсят навсякъде. Когато нещо се случи, ние, хората, веднага намираме обяснение в някакъв агент, който го е извършил. Зад всяко събитие ние виждаме като извършител или човек, или животно, или божество. Много рядко ние приемаме, че това се е случило от само себе си. ИИ трябва да подходи по същия начин като нас, хората, и да търси агентите навсякъде.

Когато ИИ намери агент, трябва да започне да го изучава и да се опитва да се свърже с него. Да намери агент, значи да го измисли. Когато ИИ измисли съществуващ агент, тогава можем да кажем, че го е намерил. Когато си измисли несъществуващ агент, тогава е по-добре да кажем, че си е измислил нещо несъществуващо. Дали агентите са реални или измислени няма голямо значение. Важното е описанието на света, получено чрез тези агенти, да е адекватно и да дава добри резултати.

2.14.1 Взаимодействие между агенти

ИИ ще изучава агентите, като ги класифицира като приятели и като врагове. Ще отбелязва дали са умни и дали са благодарни (съответно отмъстителни). ИИ ще се опитва да се свързва с агентите. За целта първо трябва да разбере към какво се стреми всеки от тях и да му предложи това, което иска агентът, и в замяна да се опита да получи нещо полезно за себе си. Тази размяна на блага се нарича изпълнение на коалиционна стратегия. Обикновено се предполага, че агентите се срещат извън света и там се уговарят каква да бъде тяхната коалиционна стратегия. Тъй като няма как агентите да се срещнат извън света, ние ще предполагаме, че те общуват вътре в света. Принципът на общуването е: „Ще ти направя добро и очаквам да ми го върнеш“. Другият принцип е: „Аз ще се държа предсказуемо и очаквам ти да разбереш какво е моето поведение и да започнеш да изпълняваш коалиционна стратегия (да се държиш така, че и за двама ни да има полза)“.

По този начин ние общуваме с кучетата. Даваме им кокал и веднага се сприятеляваме. Какво получаваме в замяна? В замяна те не ни лаят и не ни хапят, а това никак не е малко. По-нататък може да се достигне до по-сложни комуникации. Може да покажем на агента алгоритъм и да искаме от него той да го изпълни. Така може да научим кучето да дава лапа. Още по-нататък може да се достигне до език, като се асоциират обекти с явления. Например произнесената дума е явление и ако това явление се асоциира с даден обект или алгоритъм, тогава агентът може като чуе думата, да изпълни алгоритъма. Например кучето, като си чуе името, може да дойде при вас или ако чуе „чехли“, може да ви донесе чехлите.

2.14.2 Сигнали между агенти

За да говорим за взаимодействие или за преговори, трябва да имаме някаква комуникация. Тук стигаме до въпроса за подаването на сигнали между агентите. Не става въпрос за предварително уговорени сигнали, а за такива, които един от агентите решава да подава, а другите успяват да отгатнат на базата на наблюдението, което правят. Като пример ще дадем кучето на Павлов (Pavlov, 1902). Павлов е агентът, който решава да

подава сигнал, звънчейки със звънче, преди да нахрани кучето. Другият агент е кучето, което успява да разбере сигнала.

Когато един агент подава сигнал на друг, не е задължително вторият да разбира, че това е сигнал и че този сигнал е подаден от някой друг, който иска нещо да му каже. Например кучето на Павлов въобще не разбира, че Павлов е този, който звъни със звънчето и че иска да му каже, че обядът е готов. Кучето просто свързва събитието звънене със събитието храна. Тоест, когато подаваме сигнал, можем да останем анонимни. Тоест можем да повлияем на другия агент, без той въобще да разбира, че някой му влияе.

Друг начин за подаване на сигнал е да покажем нещо (да дадем някаква информация). За да покажем нещо, трябва да сме наясно кога и какво вижда другият агент. Например, когато кучето ни се озъби, то ни показва зъбите си. Ние виждаме, че кучето има зъби, а това е факт, който ние по принцип знаем, но виждаме, че кучето е решило да ни напомни за този факт, и разбираме посланието така: „Кучето ни предупреждава, че може да използва зъбите си срещу нас“.

Освен естествените (подразбиращите се) сигнали може да имаме и установени сигнали. Нека имаме група от агенти и между тях да има някакви вече установени сигнали. Когато се появява нов агент, той може да научи сигнала от един от агентите и после да го използва при комуникацията си с другите агенти. Такива сигнали са думите от естествения език. Научаваме думите от един агент (например от майка си) и след това използваме същите думи, за да комуникираме с другите агенти.

2.14.3 Обмен на информация

Когато агентите комуникират, те могат да обменят информация, да съгласуват действията си или да преговарят. Пример за обмен на информация е, когато един агент споделя някакъв алгоритъм с друг агент. Алгоритъмът може да бъде описан на естествен език, тоест може да бъде представен като последователност от сигнали (думи), всеки от които се асоциира с обект, явление или алгоритъм. Например, ако искаме да кажем на някого как да стигне до магазина, ние описваме този алгоритъм с думи. Когато казваме „отвори вратата“, разчитаме, че другият агент асоциира думата „врата“ с обекта „врата“ и думата „отвори“ с алгоритъма „отвори“. Тоест разчитаме, че другият агент знае думите и има представа за обектите, асоциирани с тези думи.

Ако приемем, че агентът пази алгоритмите в паметта си под формата на *Event-Driven* модели, тогава той трябва да може от описанието на естествен език да построи *ED* модел (ако разбере смисъла), както и обратното – да може да направи описание на естествен език на някакъв *ED* модел (стига да разполага с нужните думи).

2.14.4 Комуникационен интерфейс

Когато създаваме света на ИИ, трябва да му осигурим комуникационен интерфейс, за да му позволим да общува с другите агенти.

Например, когато създаваме автономно движещ се автомобил, трябва да му осигурим лице, за да може да комуникира с пешеходците и с другите шофьори. Автомобилът има клаксон и мигачи, но това не е достатъчно за пълноценна комуникация. Хубаво би било да добавим екран, който да изразява различни емоции. Усмивката и намигването ще са много полезни.

Ние обикновено търсим погледа на другия шофьор, защото за нас е много важно да знаем, че той ни е видял. Ако може това лице (този екран) да се обърне към нас, това би ни показало, че сме забелязани.

2.14.5 Литературен обзор

Има много статии, които се занимават с въпроса за взаимодействието между агентите. Тези статии не казват как ИИ ще открие агента, а приемат агента за вече открит и определят правила за разумно взаимодействие. Например в Goranko, Kuusisto and Rönnholm (2020) се разглежда случаят, когато всички агенти са приятели и всички са безкрайно умни. В Goranko et al. (2020) агентите комуникират на базата на това, че се досещат какво би направил другият (разчита се на това, че те са приятели и че са достатъчно умни, за да се сетят кое е от полза за всички). Най-интересното в Goranko et al. (2020) е, че там се поставят въпросите за йерархия между агентите (кой е по-важен) и за това кой бърза повече (кой колко е търпелив). Това са принципи, които се използват от реалните хора в реалния свят, и е логично ИИ също да ги използва.

Взаимодействието между агентите е толкова сложно, колкото взаимодействието между хората. Например в Mell, Lucas, Mozgai and Gratch (2020) агентите преговарят помежду си и дори могат да се лъжат един друг.

В статията Gurov, Goranko and Lundberg (2021), както и в настоящата дисертация, се разглежда многоагентна система, при която агентите не виждат всичко (*Partial Observability*). Основната разлика между Gurov et al. (2021) и настоящата дисертация е, че в Gurov et al. (2021) светът е даден (описан е чрез една релация), докато в настоящата дисертация светът не е даден и това е, което се търси.

2.15 По-нататъшна работа

В тази дисертация ръчно описахме един свят (играта шах) и направихме компютърна програма (Dobrev, 2020a), която на базата на това описание емулира света. Следващата задача, която искаме да решим, е обратната. Искаме да направим програма, която автоматично да намери същото това описание на света, което описахме ръчно. Програмата, която ще търси описанието, ще използва емуляцията на света (Dobrev, 2020a), благодарение на тази емуляция програмата ще „живее“ вътре в света и ще трябва да го разбере (т.е. да го опише).

В този случай бихме могли да шмекеруваме, защото правим програма, която трябва да намери нещо, а ние предварително знаем какво е това нещо, което тя трябва да намери. Разбира се, не трябва да шмекеруваме, защото ако го направим, ще получим програма, която би разбрала единствено и само този конкретен свят. Хубаво би било направената от нас програма да е в състояние да разбере (да опише) произволен свят. Последното изискване е твърде силно, защото това означава да построим ИИ. Затова няма да искаме програмата да може да разбере произволен свят, но ще искаме да е в състояние да разбере дадения свят (Dobrev, 2020a) и световите, които са близки до него. Колкото по-голям клас от светове е в състояние да разбере направената от нас програма, толкова по-умна ще е тя.

2.16 Заключение

Задачата е да разберем света. За да го разберем, трябва да го опишем, а за да го опишем, ни е нужен специален език за описание на светове.

Сведохме задачата за създаването на ИИ до една чисто логическа задача. От нас сега се иска да създадем език за описание на светове и този език ще е логически, защото на него ще могат да се опишат неизчислими функции. Ако езикът описваше само изчислими функции, тогава това щеше да е език за програмиране, а не логически език.

Основните градивни елементи на нашия нов език са *Event-Driven* моделите. Това са простите модули, които ще откриваме един по един. С тези модули ще представим зависимости, алгоритми и явления.

Направихме една абстракция, като въведохме обектите. Обектите не могат да бъдат наблюдавани директно, а ги засичаме индиректно, като наблюдаваме техни свойства. Свойството е специално явление, което се наблюдава, когато виждаме обект с това свойство. Тоест свойството също се представя с *ED* модел.

Следващата абстракция, която въведохме, са агентите и те също не могат да бъдат наблюдавани директно, а ги засичаме индиректно чрез техни действия.

Създадохме език за описание на светове. Това не е напълно завършен език, а е само неговата първа версия, която се нуждае от допълнително развитие. Не дадохме формално описание на създадения от нас език, а го представихме с три примера. Тоест вместо формално да описваме езика, ние написахме описанията на три конкретни свята. Това са два варианта на играта шах (с един и с двама агенти) и свят, който представя работата на машина на Тюринг.

Забележка: Не е голям проблем да се направи формално описание на език, което да покрива трите свята, които сме използвали като пример, но целта е друга. Целта е да се направи език, който може да опише произволен свят, и този универсален език да се опише формално. Това е по-трудна задача, която не сме решили.

Показахме, че езикът за описание на светове може чрез простите модули, от които се състои, да описва доста сложни светове с много агенти и сложни взаимоотношения помежду им. Това, което надграждаме над простите модули, не може да виси във въздуха и трябва да стъпи на някаква стабилна основа. Именно *Event-Driven* моделите са основата, която ще изгради езика за описание на светове, и базата, на която ще изградим всички по-сложни абстракции.

3 Какво ще правим, след като го направим?

3.1 ИИ не трябва да е *Open Source Project*

Кой трябва да притежава технологията „изкуствен интелект“? Тази технология трябва да е на всички, но не самата технология, а плодовете, които тя ще ни даде. Разбира се, не трябва да позволяваме ИИ да попада в ръцете на безотговорни хора. Аналогично, ядрените технологии трябва да носят полза на всички, но тези технологии трябва да се пазят в тайна и да не са общодостъпни.

3.1.1 Въведение

Има много хора, които защитават идеята, че технологията ИИ трябва да се разпространява свободно и дори че тя трябва да бъде *Open Source Project*. Между тях има дори отговорни и сериозни хора, какъвто е президентът Макрон (Macron, 2018). Тук ще се опитаме да поспорим с тези хора и да им обясним колко погрешно и дори пагубно би било подобно решение.

Когато президентът Макрон (Macron, 2018) говори за отворени алгоритми, може би той по-скоро има предвид собствеността върху тези алгоритми. Разбира се, няма нищо лошо собствеността да бъде на всички, но това не значи, че кодът на тези алгоритми може да бъде общодостъпен. Например една ядрена електроцентрала може да бъде държавна, тоест на всички, но това не значи, че технологиите, използвани в тази централа, са общодостъпни и че всеки може да вземе чертежите и по тях да направи собствена ядрена централа.

В момента отношението към технологията „изкуствен интелект“ е изключително безотговорно. Ние се намираме в зората на развитието на тази технология и въобще не можем да си представим каква мощ и неподозирани възможности крие това изобретение. Какво се е случило през 1896 година? Тогава Анри Бекерел (Becquerel, 1896) открива, че ако постави в чекмедже парче уранова руда върху фотографска плака, то след време плаката се осветява. Ако постави метален ключ между плаката и рудата, то изображение на ключа се отпечатва върху плаката. Така Бекерел открива радиоактивността, но по това време той въобще не може да си представи потенциала, който крие тази технология. Експериментът на Бекерел е забавен и е по-скоро нещо като фокус. Същото в момента е положението с изкуствения интелект. Появяват се експерименти, които са интересни и забавни, но хората въобще не си представят докъде може да ни доведе тази технология.

Можели ли са хората през 1896 година да предвидят колко мощна и опасна е ядрената технология? Тогава не е имало как да се досетят. Това става по-късно, когато откриват колко много енергия се отделя при разпада на атомното ядро.

Можем ли сега да се досетим колко опасна е технологията „изкуствен интелект“? Да, и повечето разумни хора се досещат, макар и да не осъзнават действителния мащаб на това откритие.

Всеки разумен и отговорен човек трябва да си зададе въпроса дали да участва в разработката на новата технология, или да остави това на глупавите и безотговорните.

В тази дисертация се занимаваме с технологичните катастрофи, които могат да се предотвратят, а не с неизбежните последствия, които няма как да бъдат предотвратени. Например, ако дадете на един глупак моторен трион, той може да изсече цялата гора и това е неизбежно последствие. Ако глупакът си отреже крака, това е технологична

катастрофа, която би била предотвратена, ако глупакът не беше чак толкова глупав и ако внимаваше повече.

Казваме, че един много мощен интелект е нещо опасно. Това не е нова идея. Още Adorno and Horkheimer (2002) са написали, че разумът може да бъде друга форма на варварство. Те казват, че с помощта на интелекта хората могат да променят природата по безогледен варварски начин. В Adorno et al. (2002) не се говори за изкуствен интелект, а за бюрократичната машина. Приликите между изкуствения интелект и бюрократичната машина са повече, отколкото разликите, и затова написаното в Adorno et al. (2002) може да се приеме за казано по темата. В Adorno et al. (2002) авторите разглеждат случая, когато група хора използват бюрократичната машина като оръжие с цел да подчинят останалите (тоталитарната държава). В Adorno et al. (2002) не се разглежда случаят, когато бюрократичната машина излиза извън контрол и започва да действа против волята на хората, защото това е невъзможно. Обществото като цяло винаги може да промени законите и правилата, които управляват бюрократичната машина. Тоест обществото като цяло няма как да загуби контрола върху бюрократичната машина, но отделният човек няма такъв контрол. За отделния човек бюрократичната машина е даденост, която той не може да промени. Аналогична е ситуацията с изкуствения интелект. Обществото като цяло ще запази контрола си върху ИИ, освен ако не сме достатъчно глупави да го изпуснем, но за отделния човек ИИ ще е даденост, която не може да бъде променена. Последното е едно от неизбежните последствия от появата на ИИ, което излиза извън обхвата на темите на тази дисертация.

3.1.2 Какво може да се случи?

Може да се случи катастрофа. Такава катастрофа може да е предизвикана умишлено или неволно. При ядрените технологии имената на две такива катастрофи са Хирошима и Чернобил. Първата е предизвикана умишлено, а втората – поради глупост и невнимание.

Умишлена катастрофа означава някой да реши да използва новата технология със зъл умисъл, тоест като оръжие. Тук понятието „зъл умисъл“ е относително, защото всеки създател на оръжие смята, че създава нещо полезно и че убивайки хора, той спасява живота на други хора. Обикновено се твърди, че убиваме малко, за да спасим много, или поне че убиваме от чуждите, за да спасим от нашите.

Може ли ИИ да убива? Не действат ли законите на роботиката (Asimov, 1950), които Айзък Айзимов е измислил? Всъщност тези закони са едно добро пожелание и те по никакъв начин не задължават създателите на ИИ да се съобразяват с тях. В момента технологиите, които претендират да имат нещо общо с ИИ, се използват предимно за оръжия. Например така наречените „умни бомби“. Обикновено се твърди, че глупавата бомба убива наред, докато умната убива само тези, които сме ѝ казали да убие. Тоест умната бомба е по-малко кръвожадна и по-хуманна. Това последното е по-скоро оправдание за създателите на умни бомби. Тези бомби са по-мощно оръжие от глупавите бомби и с тях можем да убием повече хора, отколкото със старите глупави бомби.

Нека си представим, че се е случила технологична авария и някой е изпуснал духа от бутилката и е загубил контрола над ИИ. Ако гледаме на ИИ като на оръжие, нека си представим, че някой използва това оръжие срещу нас. По този начин отношението ни към използването на ИИ като оръжие ще е строго негативно, защото отношението към едно оръжие много зависи от това дали ние го използваме, или някой го използва срещу нас.

Имаме ли шанс да преживеем подобна технологична авария? Отговорът е: нямаме никакъв шанс. Във фантастични филми от рода на „Терминатор“ (Cameron, 1984) се описва как хората воюват с роботите, но там имахме едни много тъпи роботи, които са много по-тъпи от хората. Истината за ИИ е, че той ще е много по-умен от който и да е човек. Тоест идеята за равноправно състезание между хора и роботи е безсмислена. Също толкова безсмислено е да организираме равноправно състезание по тичане между хора и автомобили. Хората няма да имат никакъв шанс, защото автомобилите са много по-бързи от хората.

Тоест ние не можем да си позволим подобна технологична авария, просто защото няма да я преживеем. В историята си човечеството е преживяло много природни бедствия и технологични аварии, но винаги ефектът от тези аварии е бил локален. Например аварията в Халифакс причинява взрив, който разрушава града. Въпреки това пораженията са локални и са ограничени до един град. Като възможно най-страшния сценарий за катастрофа се споменава ядрената война, но дори и това би имало само локални последици. Една подобна война би могла да унищожи градовете, но все някое от селата би оцеляло. Тоест дори и възможна ядрена война не представлява такъв риск, какъвто е евентуалната загуба на контрола над ИИ.

3.1.3 Можем ли да заключим звяра в клетка?

Можем ли да създадем ИИ, но за да сме сигурни, че няма да направи някоя беля, да го затворим в една виртуална реалност? Така ще можем да го наблюдаваме отстрани и да го изучаваме, но винаги ще можем да дръпнем щепсела и да го изключим, ако решим.

Да, можем. Ако ИИ няма вход и изход (тоест уши и уста), тогава той не може целенасочено да повлияе на външния свят. Дори и да повлияе, то това няма да е целенасочено, защото той за външния свят въобще няма да знае. Например ние хората знаем ли дали не сме в матрицата (филма „Матрицата“ – The Wachowski Brothers, 1999). Както ние не знаем дали нашият свят е истински или виртуален, така и ИИ няма да знае.

Достатъчно е само ИИ да няма вход (тоест да не получава никаква информация от външния свят). Що се отнася до изхода, щом ние наблюдаваме ИИ, то той има изход (ръце и уста), защото чрез своето поведение той ще влияе на нас и оттам, чрез нас, ще повлияе на външния свят.

Тоест рецептата е много проста. Държим ИИ в една виртуална реалност и така избягваме риска от технологична катастрофа. Да, но ние ще искаме ИИ да ни каже нещо за реалния свят. Например да ни направи прогноза за времето или да ни каже какви ще са цените на борсата. Може да поискаме да свърши някаква работа, например да измие чиниите или да измете пода. За всичките тези неща ще е нужно да го пуснем от виртуалната реалност и да му позволим да влезе в реалния свят. Дори и да се уговорим да не го пускаме, все ще се намери някой, който ще се изкуши и ще го пусне.

Можем ли да заключим ИИ в клетка, без да го лишаваме от информация за външния свят? Тоест да може да чува реалния свят и да го гледа през решетката, но въпреки това да си запазим възможността винаги да можем да дръпнем щепсела и да го изключим.

Може ли лъвът да избяга от зоологическата градина? Може, макар че това е малко вероятно, защото лъвът е много глупав. Достатъчно е да има едно обикновено резе на вратата на клетката и лъвът няма да се сети как да си отвори. Маймуната има по-големи шансове да избяга, защото тя е по-умна от лъва. Ако разчитаме на обикновено резе, това няма да спре маймуната, защото тя ще се сети как да го отвори. Най-трудно е да заключим

човек. Бягства се случват дори и в най-добре охраняваните затвори. Хората са много умни и почти винаги намират начин да се измъкнат. Нека сега си представим, че сме се опитали да заключим едно същество, което е много по-умно от нас. Нека си представим човек, охраняван от маймуни. Ще успее ли човекът да надхитри маймуните и да избяга?

Добре, но ние винаги ще имаме възможността да дръпнем щепсела и да изключим ИИ, ако решим, че той е излязъл извън контрол. Да, но може и да не можем да го изключим. Когато ИИ излезе извън контрол, той може да реши да не ни позволява да го изключим.

След като ИИ не може да бъде заключен в клетка, можем ли да го използваме в реалния свят? Да, можем, но трябва да сме сигурни, че сме създали един добронамерен ИИ, който няма да се опитва да вземе властта от нас. Например кучето може да избяга и може да ни ухапе, но не го прави, защото е добронамерено.

Тоест, ако внимаваме какъв ИИ създаваме, няма да се случи технологична катастрофа. Това означава, че хората, на които ще разрешим да се занимават с тази технология, трябва да са достатъчно умни и отговорни. Ако такива бяха хората, занимаващи се с ядрени технологии, нямаше да се случи нито Хирошима, нито Чернобил.

3.1.4 Принципа на моркова и тоягата

Ето един много прост пример за технологична катастрофа. Когато говорим за ИИ, предполагаме, че той се обучава с поощрения и наказания (тази концепция е известна като *Reinforcement Learning*). Това е принципът на моркова и тоягата. Целта на ИИ е ясна: повече поощрения и по-малко наказания. Можем да стартираме такъв ИИ и да дадем на човека, който го управлява, два бутона, с които да поощрява и да наказва ИИ. Проблем би възникнал, ако ИИ реши да забрани на човека да натиска бутона за наказание и да го принуди непрекъснато да натиска бутона за поощрение. По този начин ИИ ще превърне човека в свой роб, който е принуден непрекъснато да натиска бутона за поощрение.

Подобно нещо би се случило, ако магарето вземе властта и забрани на стопанина си да използва тоягата и ако го принуди по цял ден да го храни с моркови. Слава богу, магарето не е достатъчно умно, за да вземе властта, и това не може да се случи.

3.1.5 Можем ли да не създаваме ИИ?

Можем ли да се уговорим да не отваряме кутията на Пандора? Могат ли учените, които се занимават с изследвания в областта на изкуствения интелект, да се съберат и да се уговорят да не правят това откритие? Отговорът е, че това няма как да се случи. Дори и част от учените да успеят да постигнат подобно споразумение, ще има и такива, които няма да са част от споразумението или ще са част, но няма да се съобразят и ще го нарушат.

Подобно нещо се случва с ядрената технология. Физикът Вернер Хайзенберг твърди, че през 1941 година се среща тайно с бившия си учител Нилс Бор в Копенхаген и те двамата постигат уговорка да не създават атомната бомба. Нилс Бор, от своя страна, отрича да е сключвал подобно споразумение. Имало ли е или е нямало подобно споразумение е без значение, защото и Германия, и САЩ не спират ядрените си програми. Възможно е отделни хора да са саботирали развитието на ядрените технологии, но е имало и достатъчно много хора, които са продължили да работят по темата.

3.1.6 Защо трябва да засекретим ИИ технологията?

Всяка опасна технология се засекретява и достъпът до нея се ограничава. Пример за това са огнестрелните оръжия. Защо не позволяваме на децата да си играят с картечници? Каква беля може да се случи? Детето може да застреля един-двама, най-много сто човека. С помощта на ИИ технологията детето може да направи много по-голяма беля. Например детето може да зададе задача на ИИ да избие всички, които не му харесват, и това може да се окаже, че са всички хора, включително и този, който е задал задачата.

Сега ще ми кажете, че ИИ технологията е много сложна и едно дете не може да се справи с нея. Аз не твърдя, че едно дете може да създаде тази технология, но твърдя, че ако му я предоставим *Open Source*, то би могло да я използва. Същото е и с картечницата. Едно дете не може само да си направи картечница, но ако му дадем една, то би могло да стреля с нея. В това няма нищо сложно. Дърпаш спусъка и тя започва да стреля.

Подобно е положението с хаковете за компютри. Това са пропуски в сигурността на вашия компютър, които позволяват да се проникне дистанционно в него. Хаковете са или злоумишлено направени, или са резултат на неволна грешка. Обикновено при създаването на една операционна система се оставят пропуски в сигурността, които по-късно да позволят проникването в компютрите, работещи с тази операционна система. Идеята на тези хакове е да се пазят в тайна и да се ползват само от техните създатели. Какво се случва на практика? Някой открива някакъв хак и го публикува в мрежата. Идеята е да може всеки да се защити. Резултатът е, че всеки може да го използва и да проникне в компютъра ви.

Целта на умишлените хакове е да могат тайните служби да влизат и да контролират вашия компютър. Аз лично нямам нищо против тайните служби да влизат и да контролират моя компютър, защото знам, че това са хора отговорни и че ще влязат и излязат от моя компютър и аз дори няма и да разбера, че са влизали.

Какво става обаче, когато в компютъра ви проникне някой тийнейджър? Той ще иска да отбележи своето посещение и ще направи някоя пакост. Как тийнейджърите успяват да открият пропуските в сигурността, толкова ли са умни? Не е нужно да са умни. Те просто използват публикувани хакове, които са *Open Source* и които могат да се ползват от всеки. Ако някой тийнейджър е достатъчно умен сам да открие хак, то той вероятно ще е и достатъчно отговорен, за да не прави пакости в компютъра ви.

3.1.7 Секретни списания

Мисля, че вече сте съгласни, че технологията ИИ не трябва да попада в ръцете на деца и на безотговорни хора. По същия начин сте съгласни, че на децата не трябва да им разрешаваме да си играят с картечница.

Може ли да дадем на децата едно достатъчно добро упътване, което да им позволи сами да си направят картечница? Разбира се, най-малките няма да се справят, но техните батковци биха могли, особено ако упътването е достатъчно подробно и добре написано. Може ли да смятаме, че всеки, който е достатъчно умен да направи картечница по упътване, е и достатъчно отговорен, за да я ползва? Според мен не можем да направим такова предположение и затова упътванията за това как се прави картечница трябва да са с ограничен достъп.

Същото важи и за статиите, в които се описва ИИ технологията. Първо да кажем какво е ИИ. Изкуственият интелект е програма. Една програма може да бъде написана. Написването на програмата е техническа задача, подобна на решаването на ребус. Разбира се, преди да напишем програмата, трябва да измислим алгоритъма. Трябва да си доста

умен, за да измислиш алгоритъма на ИИ, но този алгоритъм може да бъде подробно описан в някоя статия за ИИ. Ако разполагаш с такава статия, самото написване на програмата ИИ може да се окаже техническа задача. Затова, според мен, статиите за ИИ трябва да са с ограничен достъп.

Навремето в бившия Съветски съюз имаше секретни списания. Всички военни и потенциално опасни технологии се отпечатваха в такива списания. Разбира се, хората, които имаха право да четат тези списания, бяха внимателно подбрани и техният кръг беше силно ограничен. Смятам, че днешните ИИ технологии трябва да се публикуват само в такива секретни списания.

3.1.8 Сериозните списания

Може ли в сериозно научно списание да се появи статия, описваща алгоритъма на ИИ? Това е почти невъзможно, защото сериозните списания имат рецензенти, които са отговорни хора и не биха допуснали една потенциално опасна статия да види бял свят. Например никое химическо списание няма да ви позволи да публикувате статия, в която се описва създаването на бомба от подръчни материали. В списание по физика по принцип бихте могли да публикувате статия свързана с устройството на атомната бомба, но само ако вътре няма опасни подробности.

Това, че сериозните списания не допускат опасни статии, не означава, че такива статии не се появяват. Учените, отхвърлени от рецензентите, публикуват своите резултати където им попадне. Често те публикуват на своите интернет страници или в различни блогове.

Нужно ли е статиите да се рецензират? В хартиените списания рецензията е неизбежна, защото хартията е ограничен ресурс и не може всеки да публикува каквото му скимне. Разбира се, хартиените списания са една отживелица от миналото. Днес имаме електронни списания, където не е нужно да се ограничава дължината на статията, нито да се спират статии.

Дори и едно електронно списание може да се претовари, защото един автор може да генерира и да изпрати един милион статии. Тоест при електронните списания имаме явлението, наречено спам. Затова е добре когато се подават статии в електронното списание, да има малка такса. Например един долар на статия или един долар на страница. Ако иска авторът да получи рецензия, таксата трябва да е значително по-голяма, за да може да се плати работата на рецензента.

Въпреки всичко рецензентите са нужни дори и в електронните списания, но не за да казват „да“ или „не“, а за да оценяват статиите и да насочват читателите струва ли си тази статия да бъде прочетена. Тоест рецензентите са нужни, но не в качеството им на цензори, а в качеството им на критици. В литературата имаме литературни критици, които оценяват романите и насочват читателите. Тези критици застават зад написаното с името си и носят отговорност за критиката си, защото ако заблудят читателя, той повече няма да вярва на тяхната критика.

Ако списанието е секретно, то рецензентът ще е нужен, за да каже какво е нивото на секретност на дадена статия. Тоест колко ограничен да е кръгът от хора, които ще могат да я прочетат.

Това, че списанието е секретно, ще означава, че само проверени, достатъчно отговорни хора ще могат да го четат, но там всеки трябва да може да публикува. Ако ограничим хората, които имат право да публикуват, резултатът ще е, че голяма част от учените ще продължат да публикуват там, където им попадне.

3.1.9 Заключение компютри

Както вече казахме, ИИ е програма и това е една много опасна програма. Затова не трябва да позволяваме на безотговорни хора да си играят с нея. Една програма има смисъл, само ако имате компютър, на който да я пуснете. Програмата без компютър представлява просто безсмислен текст.

Днес всеки тийнейджър разполага с много мощен компютър и може да пусне на този компютър каквато си поиска програма. Това, което навремето беше супер компютър сега е по-слабо от телефона, който носите в джоба си.

Много хора се притесняват от това, че Северна Корея разполага с термоядрено оръжие. Аз повече се притеснявам от това, че те разполагат със суперкомпютър, на който биха могли да стартират програмата ИИ и да направят много по-големи поразии, отколкото би направила една термоядрена бомба.

Все пак Северна Корея се управлява от пълнолетни хора, които носят отговорност за действията си, но ние позволяваме на всяко непълнолетно дете, което по закон не отговаря за действията си, да притежава компютър и да пуска на него каквато си поиска програма.

Щом не позволяваме на децата да си играят с огнестрелно оръжие, защо им позволяваме да си играят с компютри? Дали не трябва да забраним на обикновените хора да притежават компютър? Дали не трябва за притежаването на компютър да се иска разрешение, както се иска за притежаването на огнестрелно оръжие?

По времето на Китайската империя е имало закон, забраняващ на обикновените хора да притежават оръжие. Това е причината, поради която в Китайската империя са измислени различни техники за ръкопашен бой, както и за бой с пръчка и с разни селскостопански инструменти (например нунджако). Дали не е дошло времето да се приеме закон, забраняващ на обикновените хора да притежават компютри?

Идеята да се ограничи притежаването на компютри вече е реализирана в известна степен. Например смартфоните представляват компютри, но това са заключени компютри, на който не можеш да пуснеш каквато си поискаш програма, а само програма, проверена и одобрена от някой, който решава вместо нас коя програма е опасна и коя е безопасна.

Постепенно в заключени компютри се превръщат таблетите и лаптопите. Все още огромната част от настолните компютри не са заключени и позволяват на хората да програмират и да пускат на тях собствени програми. Предполагам, че и това ще е до време и че идва денят, в който всички компютри ще са заключени и притежаването на отключен компютър ще се наказва като едно от най-опасните углавни престъпления.

Преди двадесетина години хората оставяха компютрите си включени през нощта и позволяваха всеки желаещ да ги ползва и да изпълнява програми (говоря за компютрите, работещи под *UNIX*). Тоест имаше един огромен суперкомпютър, който беше на разположение на всеки, който пожелае да си поиграе с него. Днес, благодарение на технологията *Bitcoin*, този ресурс вече не е свободен. Сега всички свободни компютърни ресурси са впрегнати да копаят биткойни. Дори някой да има свободен компютърен ресурс, той не би го предоставил за свободно ползване, защото знае, че някой друг ще се възползва, ще изкопае биткойни и ще спечели за негова сметка.

3.1.10 Заключение

Трябва много сериозно да се отнесем към технологията ИИ и да засекретим всички програми, които имат нещо общо с тази технология. Трябва да засекретим и статиите в

областта на ИИ, и дори трябва да заключим компютрите, за да не може всеки да си играе и да експериментира с ИИ технологиите. Тези експерименти трябва да бъдат разрешени само на хора, които са достатъчно умни и отговорни. В момента, за да работиш като лекар, трябва да отговаряш на куп изисквания, а за да правиш изследвания в областта на ИИ, не се иска нищо. Това трябва да се промени и да се въведат изисквания, на които трябва да отговарят ИИ изследователите.

Технологичната катастрофа, да бъде изпуснат контролът над ИИ, може да се случи от глупост или от безотговорност. Не трябва да позволяваме с ИИ да се занимават хора с комплекс за малоценност, които биха могли да пожелаят да получат абсолютната власт и да се превърнат в нещо като господар на вселената.

От друга страна, трябва да позволим на независимите изследователи да публикуват (в секретните списания) и по този начин те да получат признание за своя труд. Разбира се, когато независимите изследователи публикуват, те трябва да получат дата и гаранция, че никой няма да се опита да оспори или открадне тяхната заслуга.

Когато говорим за технологична катастрофа, имаме предвид неща, които могат да се избегнат и които, ако сме достатъчно умни и отговорни, ще избегнем. Това са загубата на контрол върху ИИ и използването на ИИ като оръжие или като средство една група хора да подчини останалите.

Има много други последствия от ИИ технологията, които са неизбежни. Например това, че хората ще си загубят работата, е такова последствие, което не можем да предотвратим. Освен че не можем да го предотвратим, ние не искаме да го предотвратяваме, защото никой от нас не иска да е принуден да работи. Бихме работили за удоволствие, но не искаме да работим по принуда.

Много хора се притесняват, че тайните служби им ровичкат из компютрите. Днес тайните служби виждат всичко и знаят всичко. Господ също вижда всичко и знае всичко, но това не притеснява никого. Разбира се, Господ е дискретен и добронамерен. Той няма да каже на жена ви, че сте ѝ изневерил, нито ще се възползва от информацията на вашия компютър за своя изгода. Тайните служби също са дискретни, но невинаги са добронамерени. Неслучайно най-големите бандити обикновено са бивши или настоящи служители на тайните служби.

Няма нужда да се притесняваме, от това че тайните служби виждат всичко. Това е нещо неизбежно. Глупаво е да се притесняваме от неизбежни неща, които не можем да променим. Казахме, че в тези служби работят хора отговорни, но това не означава, че са достатъчно отговорни. Начинът да избегнем проблеми не е да се крием от тайните служби, а да ги контролираме и да внимаваме кой работи там.

Моята теза е, че трябва да разрешим на тайните служби официално, без да се крият, да контролират нашите компютри. Ако го направим, ще забравим проблеми като компютърни хакове, вируси и спам. Компютрите ни ще станат сигурни и надеждни. Дори може да поискаме, когато ни гръмне харддискът, те да ни възстановят информацията. Така или иначе те пазят нашата информация при себе си.

Кой работи в тайните служби е важно, но още по-важно е на кого ще позволим да прави изследвания в областта на ИИ. Това трябва да са умни, разумни и отговорни хора, без комплекс за малоценност и без престъпни намерения. Ако разрешим на всеки, който си поиска, да се занимава с подобни изследвания и експерименти, то ще се случат технологични катастрофи, в сравнение с които Хиросима и Чернобил ще ни се видят като дребни инциденти.

3.2 Как ще изглежда животът ни след появата на ИИ?

Идеята на ИИ е, че човекът създава същество, което е несравнимо по-умно от него самия. Макар че това същество ще е добронамерено и ще ни служи вярно, за нас то може да е проблем, защото сега ние се гордеем с това, че сме най-умните и че сме по-умни от всички други животни и дори от машините. Нашият интелект е това, което ни дава самочувствието, че сме върхът на еволюцията. Сега ние управляваме планетата Земя и ние решаваме кое животно и кое растение заслужава да живее, и кое да се размножи и да заеме повече площ, и кое да бъде ограничено само в резерватите.

Въпросът е как ще изглежда нашият живот след появата на ИИ. Тогава животът ни ще бъде измамно лесен. Няма да има нужда да мислим за прехраната си, няма да ни се налага да работим, дори няма да е нужно да се забавляваме един друг, защото ИИ ще ни забавлява много по-добре, отколкото който и да е човек би ни забавлявал. Въпреки измамната простота на живота, естественият подбор ще продължи и едни ще оцеляват, а други ще изчезват.

Като говорим за естествен подбор, не говорим за умиране, а за размножаване. След появата на ИИ почти никой няма да умира. Човешкото тяло може да се ремонтира и да се клонира и да продължи да съществува практически вечно, но ние може да решим да поставим граница и да кажем, че никой няма да има право да живее повече от 120 години. Колко хора ще оставим да живеят на Земята? Може да са 7 милиарда, може да ги увеличим до 70 или до 700, но може би е добре да се сложи някаква граница, защото ако сме прекалено много, ще започнем да си пречим, а и няма да остане никакво място за другите видове.

Какво ще правим след появата на ИИ? След като няма да работим, единственото смислено нещо ще е да се отдадем на размножаване. То и сега размножаването е най-важното, но сега ние работим, за да се размножим. Когато работата не е важна, няма да са важни и парите, защото с пари измерваме труда на хората, тогава кой ще е новият критерий на естествения подбор? Сега критериите са: интелект, красота, здраве, образование, сила, смелост, бързина, честност, религия и мироглед.

Силата и бързината са били много важни в миналото, но сега, когато машините са много по-силни и по-бързи от нас, хората, силата и бързината не са най-важното. Когато машините станат по-умни от нас, тогава и интелектът няма да е най-важното. Смелостта е сложен критерий. От една страна, печелят смелите, но, от друга, най-смелите си чупят главата. Подобно е и положението с честността. Най-успешни са бизнесмените и политиците, които не блестят с особена честност, но най-нечестните влизат в затвора. Образованието е било еволюционно предимство в миналото, но днес то е по-скоро недостатък. Моят учител по рисуване казваше, че процентът на старите моми сред висшистките е много по-голям от средното, а ако една жена защити докторантура, то положението е направо неспасяемо. Тоест трябва ли образованието да бъде ценност и трябва ли да се даде по-голям шанс на по-образованите?

Що се отнася до здравето, то безспорно е ценност, но ако всички са здрави, то тогава това не може да е критерий. Красотата е друг много важен критерий, но той е твърде субективен. Кой ще определя кой е красив и кой е грозен? И сега има възможност за много сериозни козметични корекции, а след появата на ИИ ще можем да докараме какъвто си поискаме външен вид.

Кой ще определи новите критерии на естествения подбор? Дали да не оставим това на по-умния, тоест на ИИ? Градинарят определя кое цвете е красиво и интересно и кое

заслужава да се размножи и да заеме повече място в градината. Ако искаме ние да сме тези, които ще определят критериите, тогава трябва да помислим по този въпрос. Тогава вероятно най-важният критерий ще е религията и мирогледът. Господстващият мироглед ще се наложи и ще даде по-голям шанс на тези, които споделят религията на мнозинството.

Заклучение

Тази дисертация води до някои изводи. Основният извод е, че изкуственият интелект е близо и че скоро той ще дойде и коренно ще промени живота ни.

Основната промяна ще е това, че трудът ще стане безплатен. Ние сме свикнали с това, че благодарение на техническия прогрес трудът непрекъснато поевтинява. Например изкопаването на една дупка е било скъпо, когато хората са копали на ръка, но сега, когато има багери, тази цена е паднала драстично. Ние сме свикнали с това, че стоките в магазина стават все по-евтини, защото компонентата „труд“, която е включена в тях, поевтинява непрекъснато. Става дума не за поевтиняване спрямо парите, а спрямо нещо твърдо, като златото например (макар че и златото поевтинява, поради това че машините копаят много повече злато, отколкото са можели да изкопаят хората на ръка). Ние сме свикнали с поевтиняването на труда, но не сме готови за момента, в който трудът ще стане безплатен.

Следствие на тази дисертация и на нейния основен извод е патентът Dobrev (2021a). Този патент се отнася за схема за движение на автоматично метро (автоматично, в смисъл, че влаковете се движат сами, без машинисти). Автоматичното метро не е ИИ, както и автоматът за кафе не е. Разбира се, автоматичното метро е нещо, по-сложно от автомата за кафе, но все пак не е ИИ. Ние вече знаем какво е ИИ, защото в тази дисертация има дефиниция на ИИ. Тоест ние вече знаем или поне авторът си мисли, че знае какво е ИИ.

Патентът Dobrev (2021a) не е пряко следствие от тази дисертация, но причината за създаването му е основният извод, който се прави тук. Щом трудът става безплатен, тогава е безсмислено да се инвестира в труд. Повечето изобретения целят да спестят труда на хората. Всички тези изобретения стават безсмислени. Патентът Dobrev (2021a) цели спестяването на време и на енергия, а това са неща, които ще са ценни дори и след появата на ИИ. Разбира се, когато се появи термоядреният реактор, дори и енергията ще стане безплатна, но времето на хората ще си остане ценен ресурс и ние ще продължим опитите си да го пестим.

През 1988 г. на конференцията по логика, посветена на Хейтинг във Варна, присъстваше един от асистентите на Тюринг. Той се казваше Ганди и беше доайенът на конференцията. Ганди разказа как преди войната Тюринг е решил да превърне всичките си спестявания в сребро и да ги зарови. По този начин той искал да избегне очакваното обезценяване на парите. Не е искал да инвестира и в сгради, защото не се знае кои ще са сградите, които ще оцелеят до края на войната.

Тоест решението на Тюринг да купи сребро не е пряко следствие от войната, но е косвено последствие, предизвикано от очакванията му, свързани с войната. Аналогично, патентът Dobrev (2021a) не е пряко следствие от тази дисертация, но неговото създаване и инвестицията в неговото патентоване са мотивирани от основния извод, направен в тази дисертация.

По-нататък Ганди ни разказа как Тюринг забравил къде точно е закопал среброто. След войната той многократно се опитвал да го намери, но, уви, безуспешно. Дори и самият Ганди е участвал в такива експедиции, където заедно с Тюринг търсели сребро.

Изводът е, че ние може да се опитаме да се подготвим за предстоящи събития като войната и идването на ИИ, но едва ли ще успеем да го направим. Тези събития са твърде мащабни и е трудно в такива случаи човек да съобрази коя ще е най-добрата стратегия, която да избере.

Публикации

Авторът разполага със следните публикации, които са част от текста на дисертацията:

Част 1.

Dobrev, D. (2000). AI - What is this. *PC Magazine - Bulgaria*, 11/2000, pp.12-13 (on <https://dobrev.com/AI/definition.html> in English).

Dobrev, D. (2022a). The AI Definition and a Program Which Satisfies this Definition. arXiv:2212.03184 [cs.AI].

Част 2.

Dobrev D. (2022b). Language for Description of Worlds. Part 1: Theoretical Foundation. *Serdica Journal of Computing* 16(2), 2022, pp. 101-150.

Dobrev D. (2023). Language for Description of Worlds. Part 2: The Sample World. *Serdica Journal of Computing* 17(1), 2023, pp. 17-54.

Част 3.

Dobrev, D. (2019c). AI Should Not Be an Open Source Project. *International Journal "Information Content and Processing"*, Volume 6, Number 1, 2019, pp. 34-48.

Авторът разполага още с 19 публикации и един патент, които са свързани с дисертацията, но не са част от текста на дисертацията:

Dobrev, D. (1993). First and oldest application. 1993. <http://dobrev.com/AI/first.html>.

Dobrev, D. (2001). AI - How does it cope in an arbitrary world. In: *PC Magazine - Bulgaria*, February'2001, pp.12-13 (on <http://dobrev.com/AI/world.html> in English).

Dobrev, D. (2005a). A Definition of Artificial Intelligence. In: *Mathematica Balkanica, New Series*, Vol. 19, 2005, Fasc. 1-2, pp.67-74.

Dobrev, D. (2005b). Formal Definition of Artificial Intelligence. *International Journal "Information Theories & Applications"*, vol.12, Number 3, 2005, pp.277-285.

Dobrev, D. (2005c). Testing AI in one Artificial World. *Proceedings of XI International Conference "Knowledge-Dialogue-Solution"*, June 2005, Varna, Bulgaria, Vol.2, pp.461-464.

Dobrev, D. (2005d). AI in Arbitrary World. *Proceedings of the 5th Panhellenic Logic Symposium*, July 2005, University of Athens, Athens, Greece, pp.62-67.

Dobrev, D. (2007a). Parallel between definition of chess playing program and definition of AI. *International Journal "Information Technologies & Knowledge"*, vol.1, Number 2, 2007, pp.196-199.

Dobrev, D. (2007b). Two fundamental problems connected with AI. *Proceedings of Knowledge - Dialogue - Solution 2007*, June 18 - 25, Varna, Bulgaria, Volume 2, p.667.

Dobrev, D. (2008a). Second Attempt to Build a Model of the Tic-Tac-Toe Game. June'2008 (represented at KDS 08), published in *IBS ISC, Book 2*, p.146.

Dobrev, D. (2008b). The Definition of AI in Terms of Multi Agent Systems. December, 2008, arXiv:1210.0887 [cs.AI].

Dobrev, D. (2013a) Comparison between the two definitions of AI. arXiv:1302.0216 [cs.AI]

Dobrev, D. (2013b). Giving the AI definition a form suitable for the engineer. arXiv:1312.5713 [cs.AI].

Dobrev, D. (2014). Comparison between the two definitions of AI. *International Conference "Mathematics Days in Sofia"*, July 2014, Sofia, Bulgaria, pp. 28-29.

Dobrev, D. (2017a). Incorrect Moves and Testable States. *International Journal "Information Theories and Applications"*, Vol. 24, Number 1, 2017, pp.85-90.

Dobrev, D. (2017b). How does the AI understand what's going on. *International Journal "Information Theories and Applications"*, Vol. 24, Number 4, 2017, pp.345-369.

Dobrev, D. (2018). Event-Driven Models. *International Journal "Information Models and Analyses"*, Volume 8, Number 1, 2019, pp. 23-58.

Dobrev, D. (2019a). Minimal and Maximal Models in Reinforcement Learning. *International Journal "Information Theories and Applications"*, Vol. 26, Number 3, 2019, pp. 268-284.

Dobrev, D. (2019b). The IQ of Artificial Intelligence. *Serdica Journal of Computing*, Vol. 13, Number 1-2, 2019, pp.41-70.

Dobrev, D. (2021a). Метод за управление на метрото, при който влаковете се движат без да спират на всички спирки. *BG патент № 67273 B1/ 15.03.2021 г., заявка № 112419 от 01.12.2016* (<https://dobrev.com/patent.pdf>).

Dobrev, D. (2021b). Before We Can Find a Model, We Must Forget about Perfection. *Serdica Journal of Computing*, Vol. 15, Number 2, 2021, pp. 85-128.

Декларация

Авторът декларира, че дисертацията е оригинална научна разработка. Използването на предходни резултати е отразено с подходящи препратки.

Литература

Adorno, T. & Horkheimer, M. (2002) *Dialectic of Enlightenment*. Stanford University Press, 2002, ISBN: 9780804736336.

Alfonseca, M., Cebrian, M., Anta, A., Coviello, L., Abeliuk, A. & Rahwan I. (2021) Superintelligence Cannot be Contained: Lessons from Computability Theory. *Journal of Artificial Intelligence Research*, Vol. 70, 2021, pp. 65-76.

Angelova G., M. Nisheva-Pavlova, A. Eskenazi, Kr. Ivanova (2021) Role of Education and Research for Artificial Intelligence Development in Bulgaria until 2030. *Mathematics and Education in Mathematics, Proceedings of the Fiftieth Spring Conference of the Union of Bulgarian Mathematicians 2021*, ISSN:1313-3330, pp. 71-82.

Asimov, I. (1950). I, Robot (The Isaac Asimov Collection ed.). New York City: Doubleday. ISBN 0-385-42304-7.

Cameron, J. (1984). *The Terminator*. American science-fiction action film.

Church, A. (1941) *The Calculi of Lambda-Conversion*. Princeton: Princeton University Press.

Council of Europe (2022) What's AI? <https://www.coe.int/en/web/artificial-intelligence/what-is-ai>

Bach, J. (2020) When Artificial Intelligence Becomes General Enough to Understand Itself. Commentary on Pei Wang's Paper "On Defining Artificial Intelligence". *Journal of Artificial General Intelligence* 11(2):15–18.

Baldassarre, G. and Granato, G. (2020) Goal-Directed Manipulation of Internal Representations Is the Core of General-Domain Intelligence. *Journal of Artificial General Intelligence* 11(2):19–23.

Becquerel, H. (1896). "Sur les radiations émises par phosphorescence". *Comptes Rendus*. 122: 420–421.

Berkeley, I. (2020) AI: A Crowd-Sourced Criterion. A Commentary on Pei Wang's Paper "On Defining Artificial Intelligence". *Journal of Artificial General Intelligence* 11(2):24–26.

Boutilier, C., Reiter, R. & Price, B. (2001). Symbolic Dynamic Programming for First-Order MDPs. *In Proceedings of the International Joint Conference of Artificial Intelligence*, pp. 690-700.

Cao, X. (2005). Basic Ideas for Event-Based Optimization of Markov Systems. *Discrete Event Dynamic Systems: Theory and Applications*, 15, 169–197, 2005.

Cao, X. & Zhang, J. (2008). Event-Based Optimization of Markov Systems. *IEEE TRANSACTIONS ON AUTOMATIC CONTROL*, VOL. 53, NO. 4, MAY 2008.

Chollet, F. (2020) A Definition of Intelligence for the Real World? *Journal of Artificial General Intelligence* 11(2):27–30.

Crosby, M. and Shevlin, H. (2020) Defining Artificial Intelligence: Resilient Experts, Fragile Geniuses, and the Potential of Deep Reinforcement Learning. *Journal of Artificial General Intelligence* 11(2):31–34.

Dobrev, D. (1993). First and oldest application. 1993. <http://dobrev.com/AI/first.html>.

Dobrev, D. (2000). AI - What is this. *PC Magazine - Bulgaria*, 11/2000, pp.12-13 (on <https://dobrev.com/AI/definition.html> in English).

Dobrev, D. (2001). AI - How does it cope in an arbitrary world. *In: PC Magazine - Bulgaria, February'2001*, pp.12-13 (on <http://dobrev.com/AI/world.html> in English).

Dobrev, D. (2005a). A Definition of Artificial Intelligence. *In: Mathematica Balkanica, New Series, Vol. 19, 2005, Fasc. 1-2*, pp.67-74.

Dobrev, D. (2005b). Formal Definition of Artificial Intelligence. *International Journal "Information Theories & Applications"*, vol.12, Number 3, 2005, pp.277-285.

Dobrev, D. (2005c). Testing AI in one Artificial World. *Proceedings of XI International Conference "Knowledge-Dialogue-Solution"*, June 2005, Varna, Bulgaria, Vol.2, pp.461-464.

- Dobrev, D. (2005d). AI in Arbitrary World. *Proceedings of the 5th Panhellenic Logic Symposium, July 2005, University of Athens, Athens, Greece, pp.62-67.*
- Dobrev, D. (2007a). Parallel between definition of chess playing program and definition of AI. *International Journal "Information Technologies & Knowledge ", vol.1, Number 2, 2007, pp.196-199.*
- Dobrev, D. (2007b). Two fundamental problems connected with AI. *Proceedings of Knowledge - Dialogue - Solution 2007, June 18 - 25, Varna, Bulgaria, Volume 2, p.667.*
- Dobrev, D. (2008a). Second Attempt to Build a Model of the Tic-Tac-Toe Game. *June'2008 (represented at KDS 08), published in IBS ISC, Book 2, p.146.*
- Dobrev, D. (2008b). The Definition of AI in Terms of Multi Agent Systems. *December, 2008, arXiv:1210.0887 [cs.AI].*
- Dobrev, D. (2013a) Comparison between the two definitions of AI. *arXiv:1302.0216 [cs.AI]*
- Dobrev, D. (2013b). Giving the AI definition a form suitable for the engineer. *arXiv:1312.5713 [cs.AI].*
- Dobrev, D. (2014). Comparison between the two definitions of AI. *International Conference "Mathematics Days in Sofia", July 2014, Sofia, Bulgaria, pp. 28-29.*
- Dobrev, D. (2017a). Incorrect Moves and Testable States. *International Journal "Information Theories and Applications", Vol. 24, Number 1, 2017, pp.85-90.*
- Dobrev, D. (2017b). How does the AI understand what's going on. *International Journal "Information Theories and Applications", Vol. 24, Number 4, 2017, pp.345-369.*
- Dobrev, D. (2018). Event-Driven Models. *International Journal "Information Models and Analyses", Volume 8, Number 1, 2019, pp. 23-58.*
- Dobrev, D. (2019a). Minimal and Maximal Models in Reinforcement Learning. *International Journal "Information Theories and Applications", Vol. 26, Number 3, 2019, pp. 268-284.*
- Dobrev, D. (2019b). The IQ of Artificial Intelligence. *Serdica Journal of Computing, Vol. 13, Number 1-2, 2019, pp.41-70.*
- Dobrev, D. (2019c). AI Should Not Be an Open Source Project. *International Journal "Information Content and Processing", Volume 6, Number 1, 2019, pp. 34-48.*
- Dobrev, D. (2020a). AI Unravels Chess. http://dobrev.com/software/AI_unravels_chess.zip
- Dobrev, D. (2020b). Strawberry Prolog, version 5.1. <http://dobrev.com/>
- Dobrev, D. (2021a). Метод за управление на метрото, при който влаковете се движат без да спират на всички спирки. *BG патент № 67273 B1/ 15.03.2021 г., заявка № 112419 от 01.12.2016 (<https://dobrev.com/patent.pdf>).*
- Dobrev, D. (2021b). Before We Can Find a Model, We Must Forget about Perfection. *Serdica Journal of Computing, Vol. 15, Number 2, 2021, pp. 85-128.*
- Dobrev, D. (2022a). The AI Definition and a Program Which Satisfies this Definition, *arXiv:2212.03184 [cs.AI].*
- Dobrev D. (2022b). Language for Description of Worlds. Part 1: Theoretical Foundation. *Serdica Journal of Computing 16(2), 2022, pp. 101-150.*
- Dobrev D. (2023). Language for Description of Worlds. Part 2: The Sample World. *Serdica Journal of Computing 17(1), 2023, pp. 17-54.*
- Fox, J. (2020) Towards a Canonical Theory of General Intelligence. *Journal of Artificial General Intelligence 11(2):35-40.*
- Goranko, V., Kuusisto, A. & Rönholm, R. (2020). Gradual guaranteed coordination in repeated win-lose coordination games. *24th European Conference on Artificial Intelligence - ECAI 2020, Santiago de Compostela, Spain, Frontiers in Artificial Intelligence and Applications, Volume 325, pp. 115-122.*
- Gurov, D., Goranko, V. & Lundberg E. (2021). Knowledge-Based Strategies for Multi-Agent Teams Playing Against Nature. *arXiv:2012.14851 [cs.MA].*

Hernández-Orallo, J., & Minaya-Collado, N. (1998). A formal definition of intelligence based on an intensional variant of Kolmogorov complexity. Proc. intl symposium of engineering of intelligent systems (EIS'98), February 1998, La Laguna, Spain (pp. 146–163). : ICSC Press.

Hernández-Orallo, Insa-Cabrera, J., Dowe, D. L. (2011). Evaluating a reinforcement learning algorithm with a general intelligence test. In J. M. J. A. Lozano, & J. A. Gamez (Eds.), *Current topics in artificial intelligence. CAEPIA 2011*. : Springer (LNAI Series 7023).

Hernández-Orallo, Dowe, D.L. (2012). IQ tests are not for machines, yet. *Intelligence* (2012), doi:10.1016/j.intell.2011.12.001

Hernández-Orallo, Dowe, DL. (2014a). How universal can an intelligence test be?. *Adaptive Behavior*. 22(1):51-69. doi:10.1177/1059712313500502.

Hernández-Orallo, J.; Dowe, DL.; Hernández Lloreda, MV. (2014b). Universal psychometrics: measuring cognitive abilities in the machine kingdom. *Cognitive Systems Research*. 27:50-74, ISSN:1389-0417. doi:10.1016/j.cogsys.2013.06.001.

Hernández-Orallo, Javier Insa-Cabrera. (2014c). Definition and properties to assess multi-agent environments as social intelligence tests. *arXiv:1408.6350 [cs.MA]*.

Hernández-Orallo, J. (2017) Evaluation in artificial intelligence: from task-oriented to ability-oriented measurement. *Artificial Intelligence Review* 48, 397–447, ISSN:0269-2821. <https://doi.org/10.1007/s10462-016-9505-7>.

Hutter, M. (2000). A Theory of Universal Artificial Intelligence based on Algorithmic Complexity. *arXiv:cs.AI/0004001 [cs.AI]*

Hutter, M., Legg, S. (2006) A formal measure of machine intelligence, In: Proc. 15th Annual Machine Learning Conference of Belgium and The Netherlands (Benelearn'06), pages 73–80, Ghent, 2006.

Hutter, M. (2007) UNIVERSAL ALGORITHMIC INTELLIGENCE A mathematical top→down approach. In *Artificial General Intelligence, 2007*

Ivanova Kr., M. Nisheva, E. Eskenazi, G. Angelova, N. Maneva (2020) Artificial Intelligence in and for Education in Bulgaria – Measures for Achievement Reliable Intelligent Growth. *Proc. of the 13th Nat. Conf. "Education and Research in the Information Society", 2020*, pp. 7-20.

Laird, J. (2020) Intelligence, Knowledge & Human-like Intelligence. *Journal of Artificial General Intelligence* 11(2):41–44.

Lamperti, G., Zanella, M. & Zhao, X. (2020). Diagnosis of Deep Discrete-Event Systems. *Journal of Artificial Intelligence Research*, Vol. 69, 2020, pp. 1473-1532.

Legg, S. (2020) A Review of “On Defining Artificial Intelligence”. *Journal of Artificial General Intelligence* 11(2):45–46.

Lindes, P. (2020) Intelligence and Agency. *Journal of Artificial General Intelligence* 11(2):47–49.

Mikolov, T. (2020) Why Is Defining Artificial Intelligence Important? *Journal of Artificial General Intelligence* 11(2):50–51.

Macron, E. (2018). Emmanuel Macron Talks to WIRED About France's AI Strategy. 31 of March, 2018, www.wired.com/story/emmanuel-macron-talks-to-wired-about-frances-ai-strategy

Mell, J., Lucas, G., Mozgai, S. & Gratch J. (2020). The Effects of Experience on Deception in Human-Agent Negotiation. *Journal of Artificial Intelligence Research*, Vol. 68, 2020, pp. 633-660.

Moschovakis, Y. (2001). What is an algorithm? *Mathematics unlimited – 2001 and beyond*, edited by B. Engquist and W. Schmid, Springer, 2001, pp. 919-936.

Moschovakis, Y. (2018). Abstract recursion and intrinsic complexity. *Cambridge University Press, Lecture Notes in Logic*, Volume 48, ISBN: 9781108415583.

Musk, E. (2023) Pause Giant AI Experiments: An Open Letter, March 22, 2023.

OpenAI. (2022) Introducing ChatGPT. Web site. <https://openai.com/blog/chatgpt>

- Pavlov, I. (1902). The work of the digestive glands. *London: Charles Griffin & Company, Limited.*
- Schofield, M. & Thielscher, M. (2019). General Game Playing with Imperfect Information. *Journal of Artificial Intelligence Research*, Vol. 66, 2019, pp. 901-935.
- Solar-Lezama, A. (2023) AI will program itself: synthesis, learning and beyond. *Lecture from "INSAIT Series on Trends in AI & Computing", April 3, 2023, Sofia University.*
- Rapaport, W. J. (2020) What Is Artificial Intelligence? *Journal of Artificial General Intelligence 11(2):52–56.*
- Reiter, R. (2001) Knowledge in Action: Logical Foundations for Specifying and Implementing Dynamical Systems. *MIT Press, Cambridge, MA*, ISBN 0-262-18218-1.
- Retto, J. (2017) Sophia, first citizen robot of the world. *ResearchGate*, (2017).
- Rojas, R. (2020) On Pei Wang's Definition of Artificial Intelligence. *Journal of Artificial General Intelligence 11(2):57–59.*
- Rosa, M. (2020) On Defining Artificial Intelligence—Commentary. *Journal of Artificial General Intelligence 11(2):60–62.*
- Schank, R. C. (2020) What Is AI? *Journal of Artificial General Intelligence 11(2):89–90.*
- Sloman, A. (2020) A Philosopher-Scientist's View of AI. *Journal of Artificial General Intelligence 11(2):91–96.*
- Stone, P. (2020) A Broader, More Inclusive Definition of AI. *Journal of Artificial General Intelligence 11(2):63–65.*
- Sutton, R. S. (2020) John McCarthy's Definition of Intelligence. *Journal of Artificial General Intelligence 11(2):66–67.*
- The Wachowski Brothers (1999). The Matrix. Science fiction action film.
- Thorisson, K. R. (2020) Discretionarily Constrained Adaptation Under Insufficient Knowledge and Resources. *Journal of Artificial General Intelligence 11(2):7–12.*
- Tromp, J. (2021) Chess Position Ranking, <https://tromp.github.io/>
- Turing, A. (1937) "On Computable Numbers, with an Application to the Entscheidungsproblem". *Proceedings of the London Mathematical Society*. Wiley. s2-42 (1): pp. 230–265.
- Turing, A. (1950) Computing machinery and intelligence. *Mind*, 1950.
- Wang, C., Joshi, S. & Khordon, R. (2008). First Order Decision Diagrams for Relational MDPs. *Journal of Artificial Intelligence Research*, Vol. 31, 2008, pp. 431-472.
- Wang, P. (1995) Non-Axiomatic Reasoning System: Exploring the Essence of Intelligence. *Ph.D. Dissertation, Indiana University.*
- Wang, P. (2019) On Defining Artificial Intelligence. *Journal of Artificial General Intelligence 10(2) 1-37, 2019.*
- Wang, P. (2020) On Defining Artificial Intelligence—Author's Response to Commentaries. *Journal of Artificial General Intelligence 11(2):73–86.*
- Winfield, A. (2020) Intelligence Is Not One Thing. *Journal of Artificial General Intelligence 11(2):97–100.*
- Yahav, E. (2023) Generative AI for Code and Beyond. *Lecture from "INSAIT Series on Trends in AI & Computing", 27 February, 2023, Sofia University.*
- Yampolskiy, R. V. (2020) On Defining Differences Between Intelligence and Artificial Intelligence. *Journal of Artificial General Intelligence 11(2):68–70.*