

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ



سیستم‌های چندعاملی

درس ۱

مروری بر

هوش مصنوعی و عامل‌های هوشمند

A Review on
Artificial Intelligence (AI) and Intelligent Agents (IA)

کاظم فولادی قلعه

دانشکده مهندسی، دانشکدگان فارابی

دانشگاه تهران


<http://courses.fouladi.ir/mas>

هوش مصنوعی و عامل‌های هوشمند


،

هوش
مصنوعی
(AI)


هوش: در تفکر یا کنش



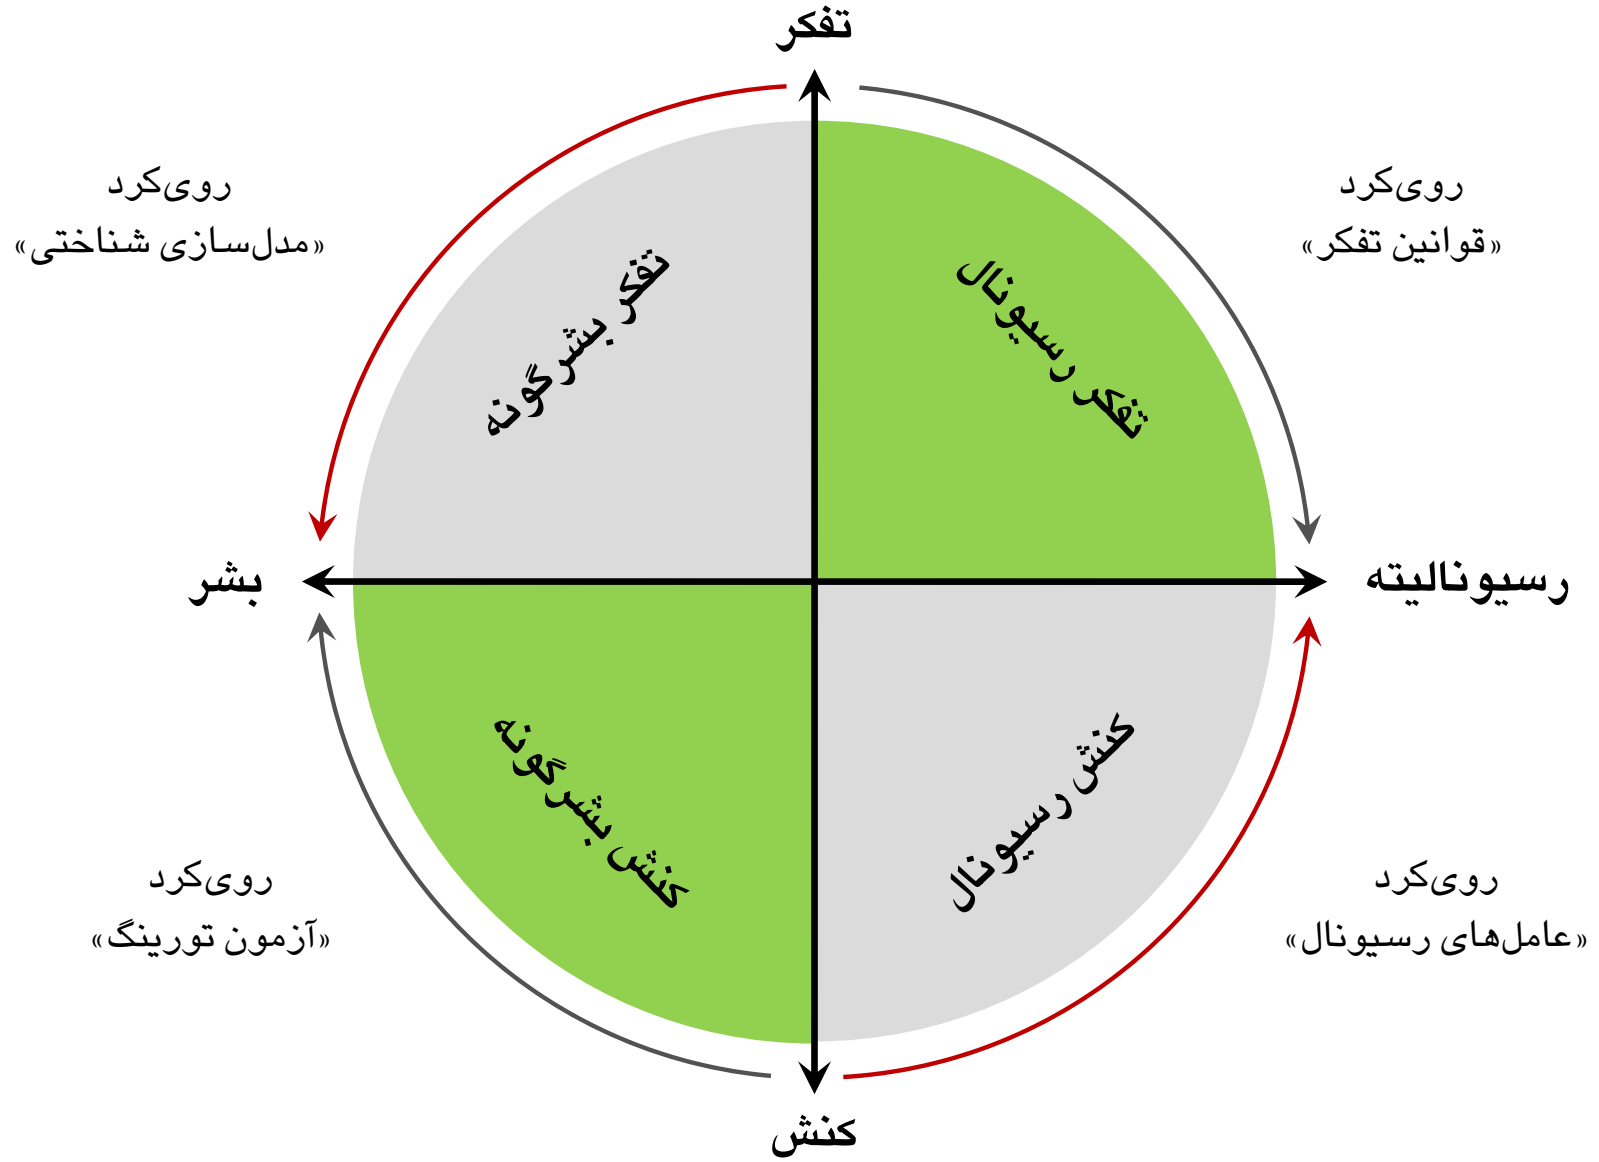
هوش: ایده‌آل هوشمندی (رسیونالیته) یا بشر



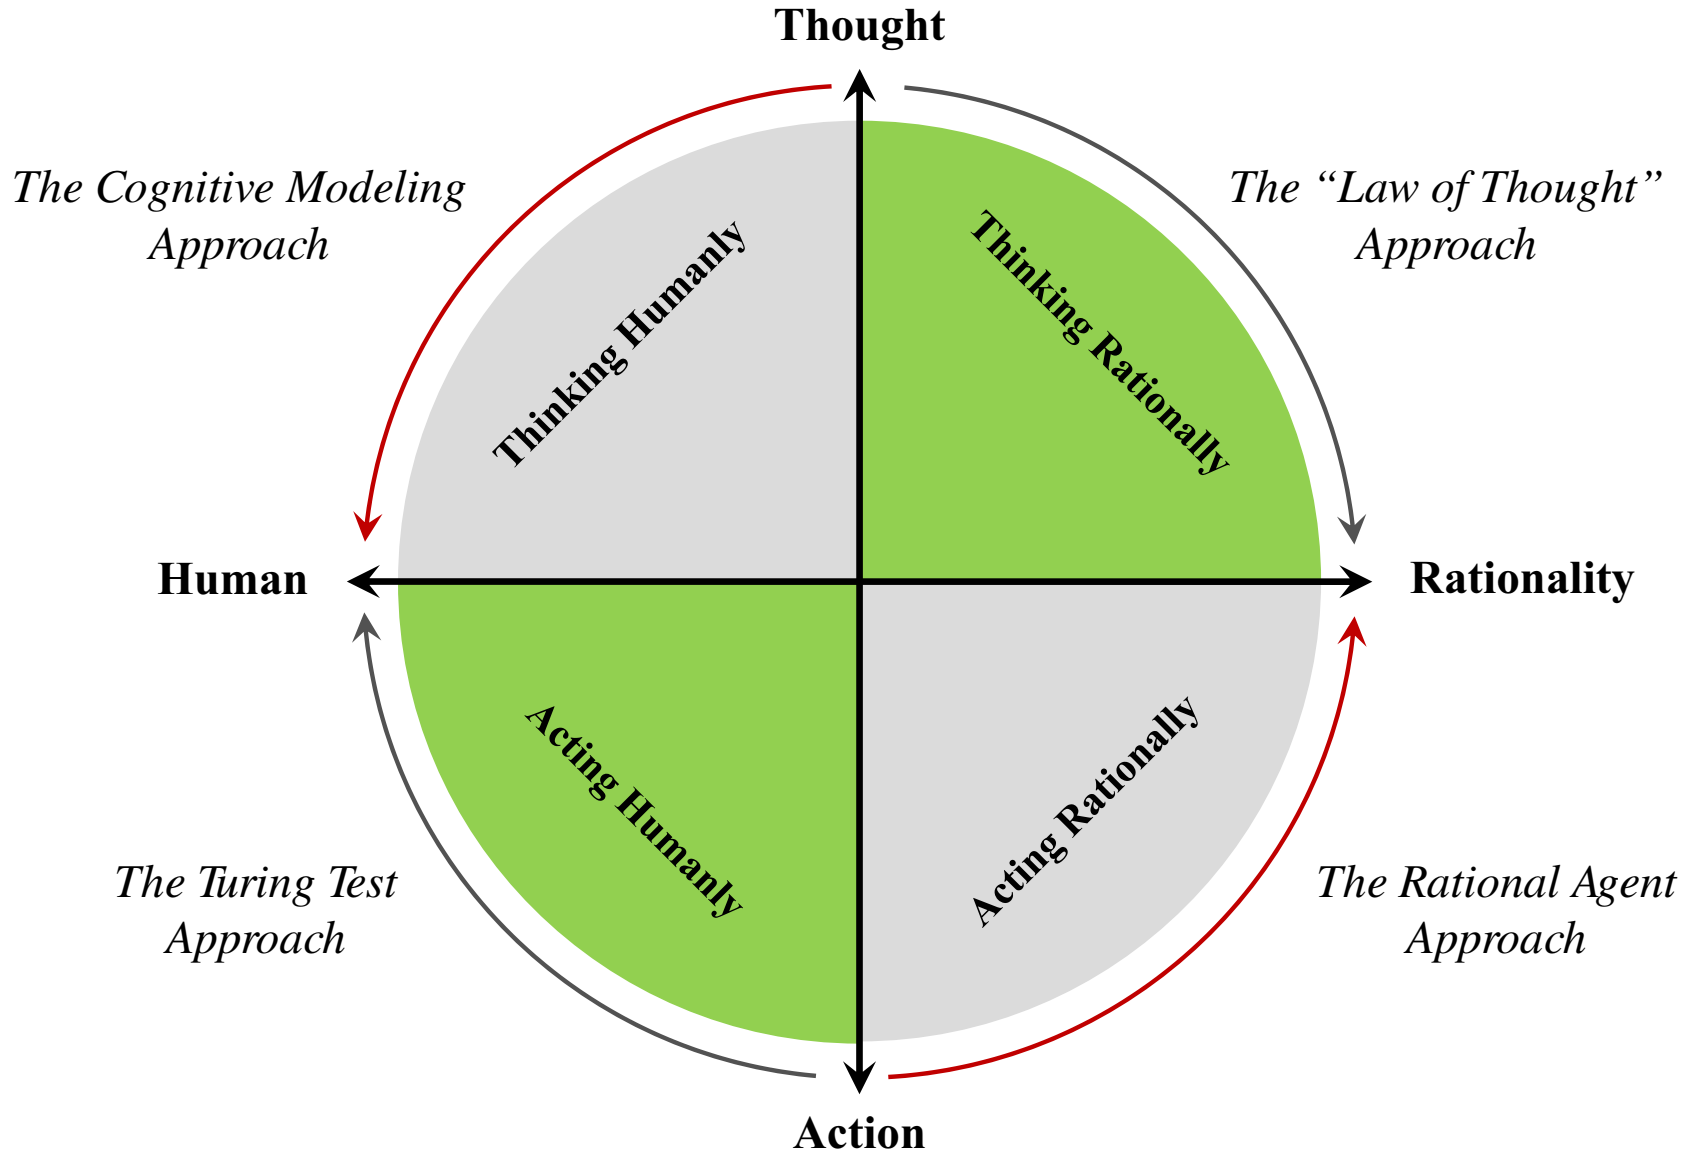
ساحات بشر در سایکولوژی



روی‌کردهای تعریف هوش مصنوعی

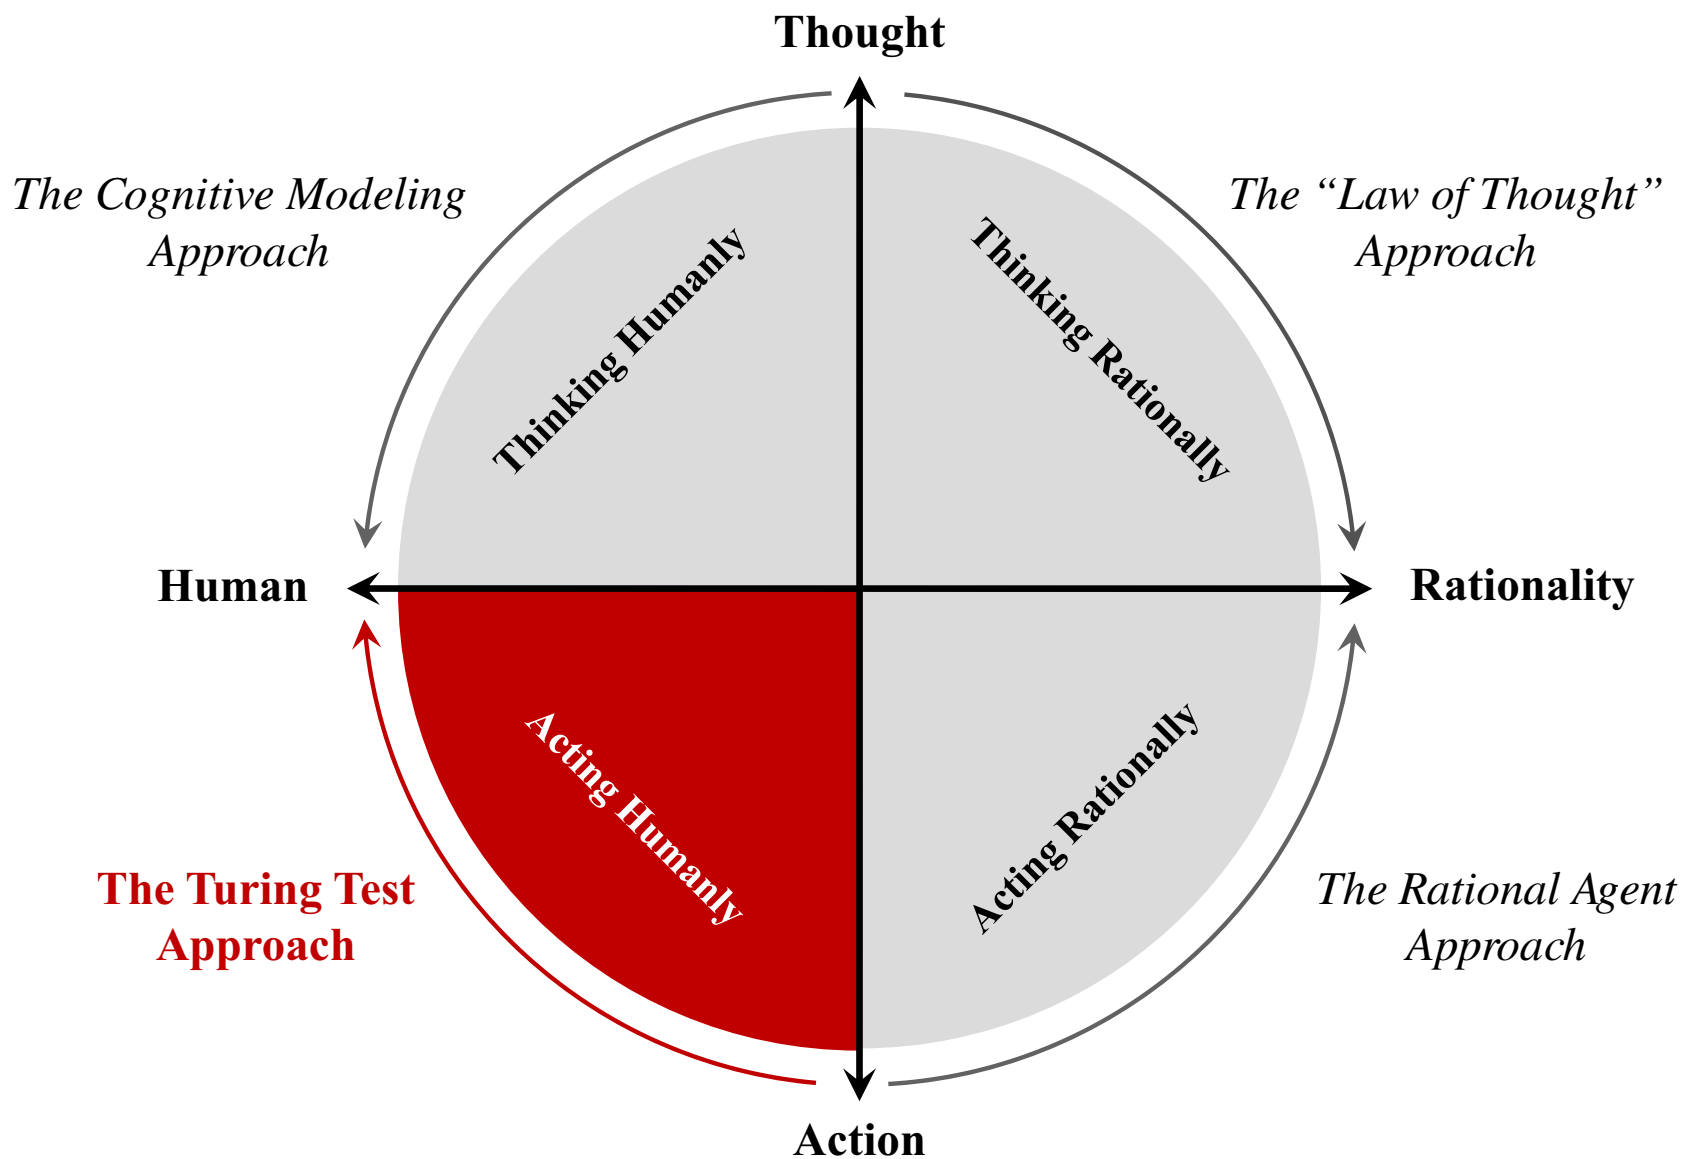


رویکردهای تعریف هوش مصنوعی



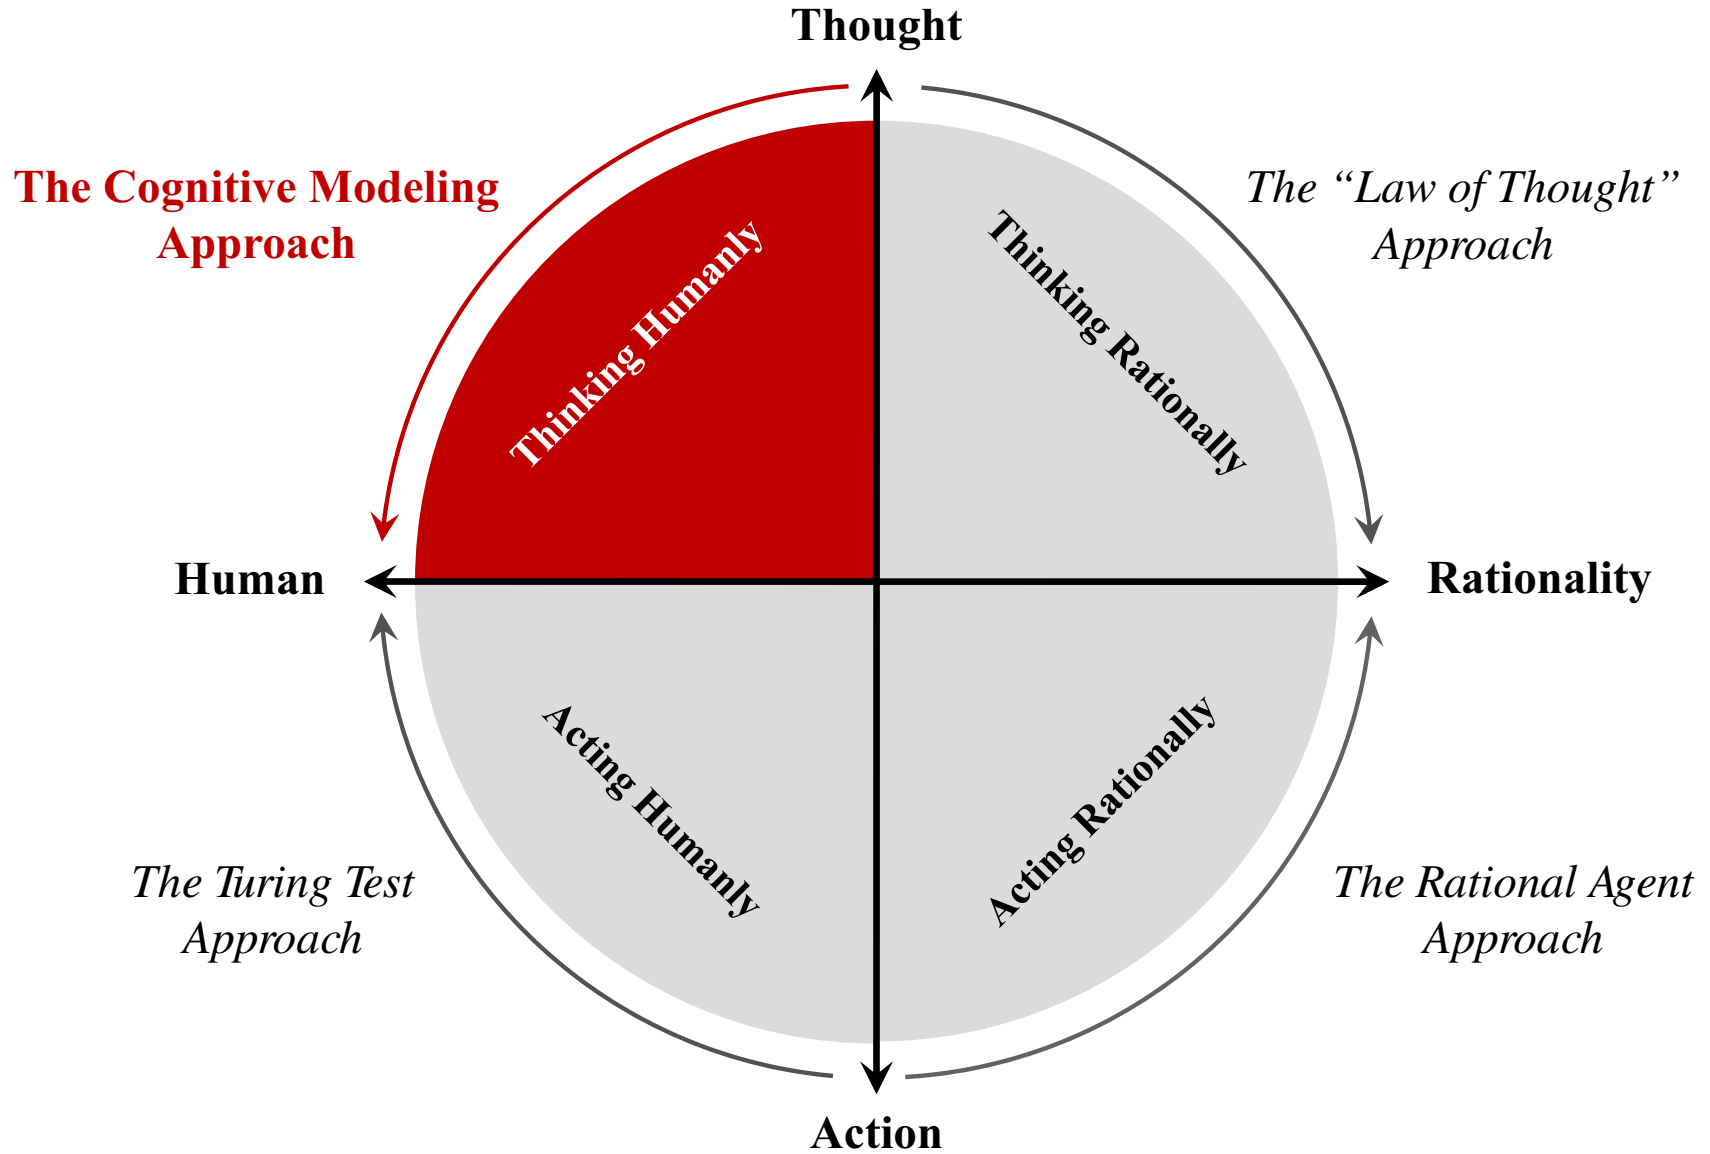
رویکردهای تعریف هوش مصنوعی

(۱) رویکرد «آزمون تورینگ» / کنش بشرگونه



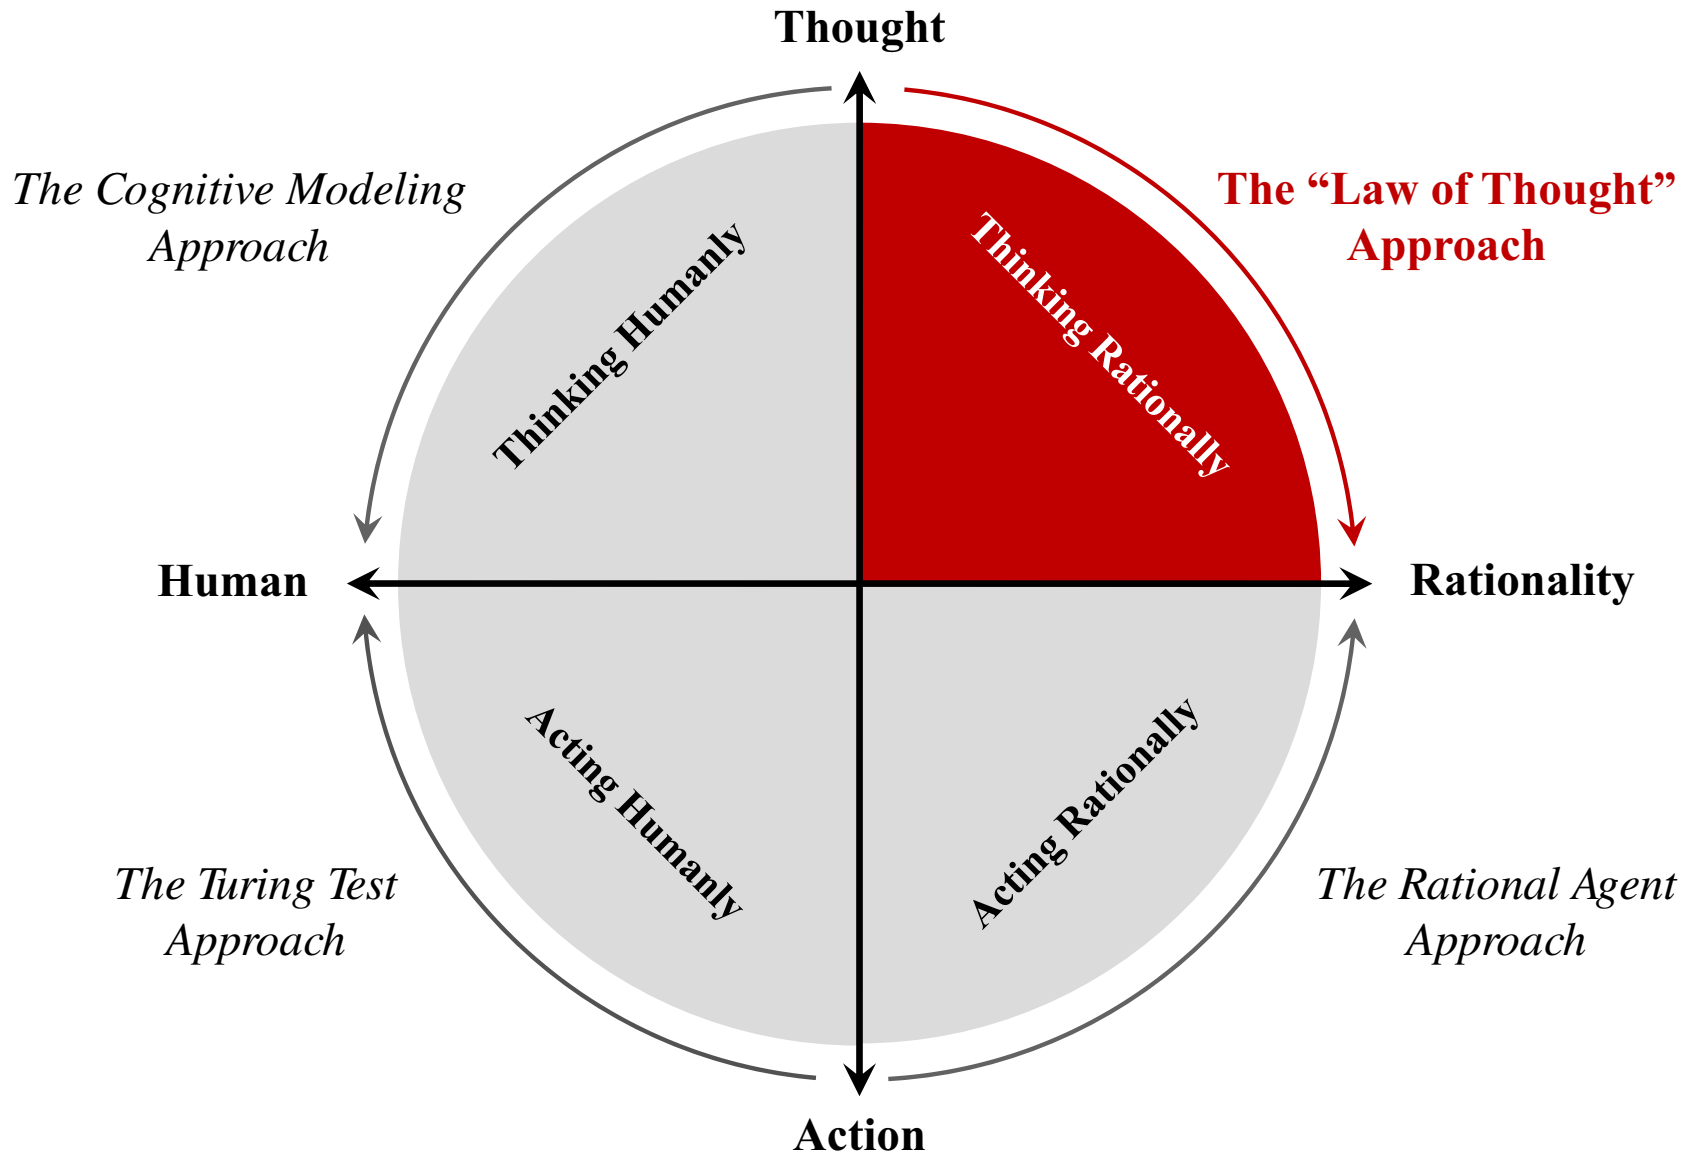
رویکردهای تعریف هوش مصنوعی

(۲) رویکرد «مدلسازی شناختی» / تفکر بشرگونه



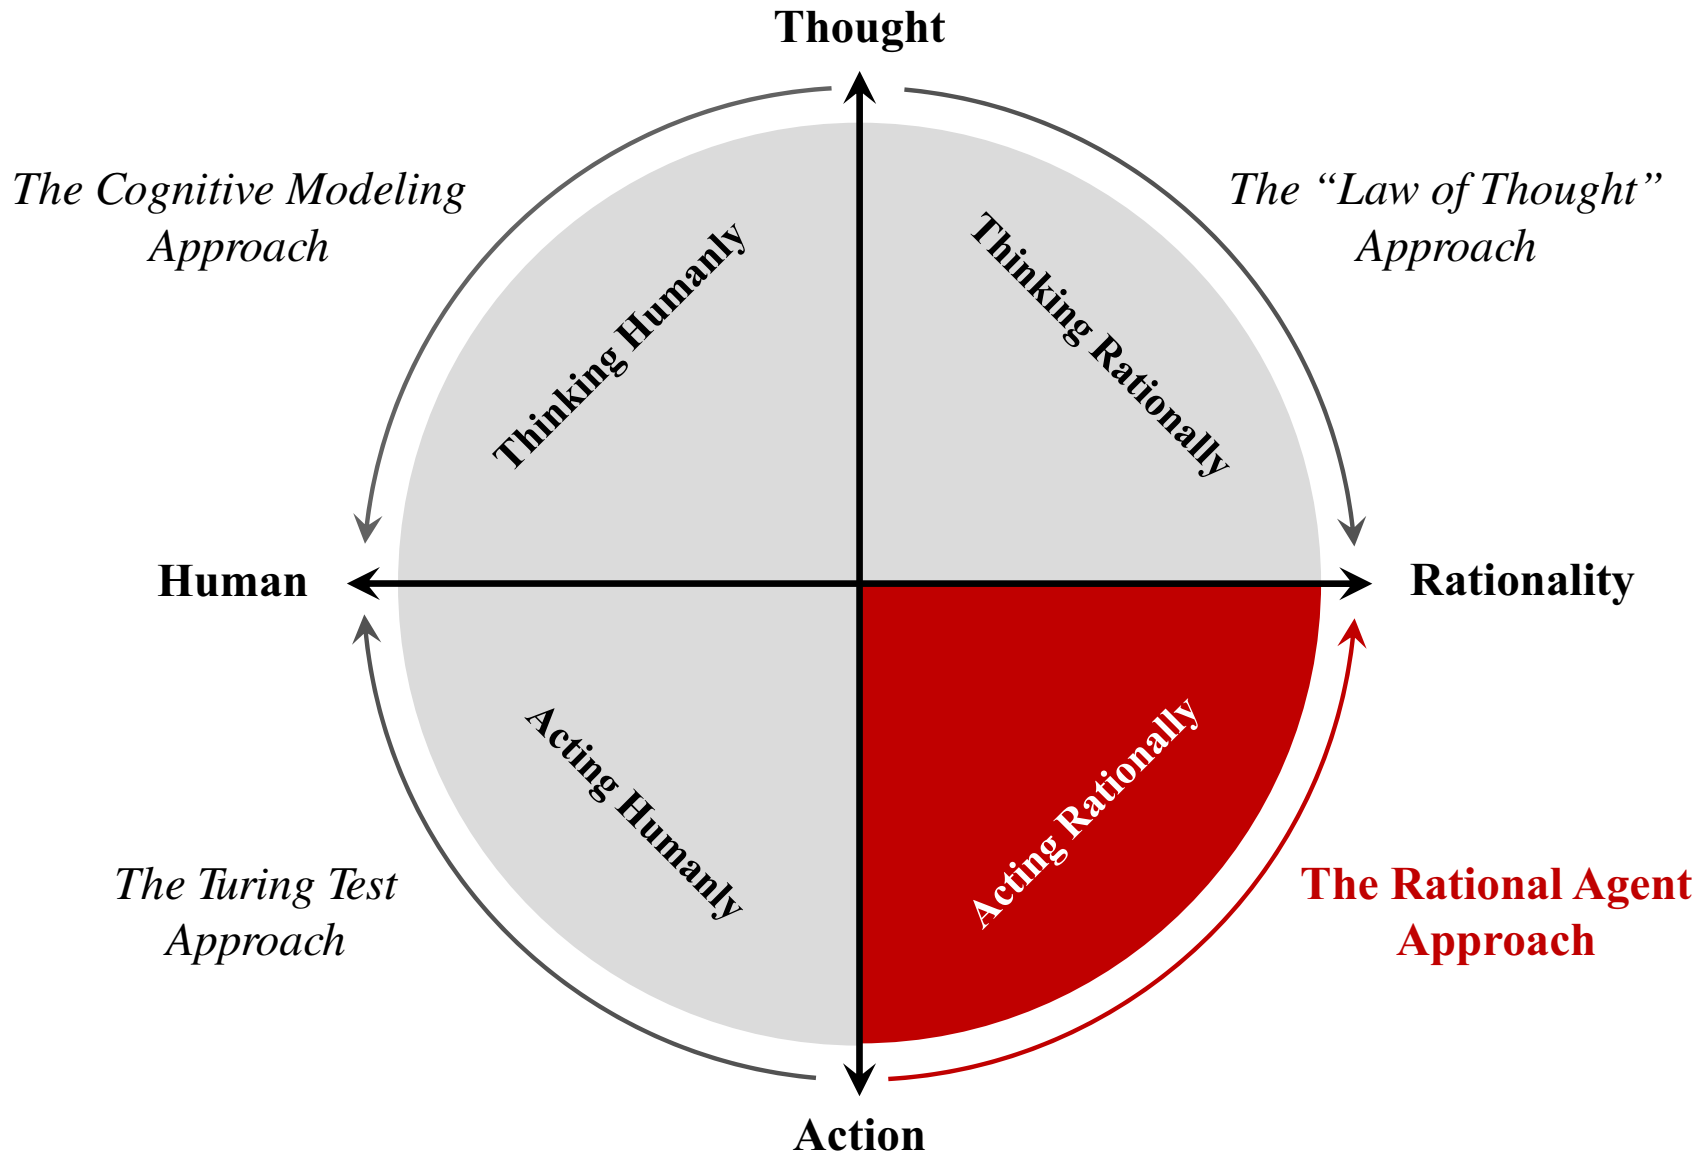
رویکردهای تعریف هوش مصنوعی

(۳) رویکرد «قوانین تفکر» / تفکر رسیونال



روی‌کردهای تعریف هوش مصنوعی

(۴) روی‌کرد «عامل‌های رسیونال» / کنش رسیونال



عامل

AGENT

عامل:
کننده‌ی کار
(چیزی که کنش می‌کند)

مشخصه‌های عامل‌های کامپیوتری (در مقابل برنامه‌های کامپیوتری معمولی)

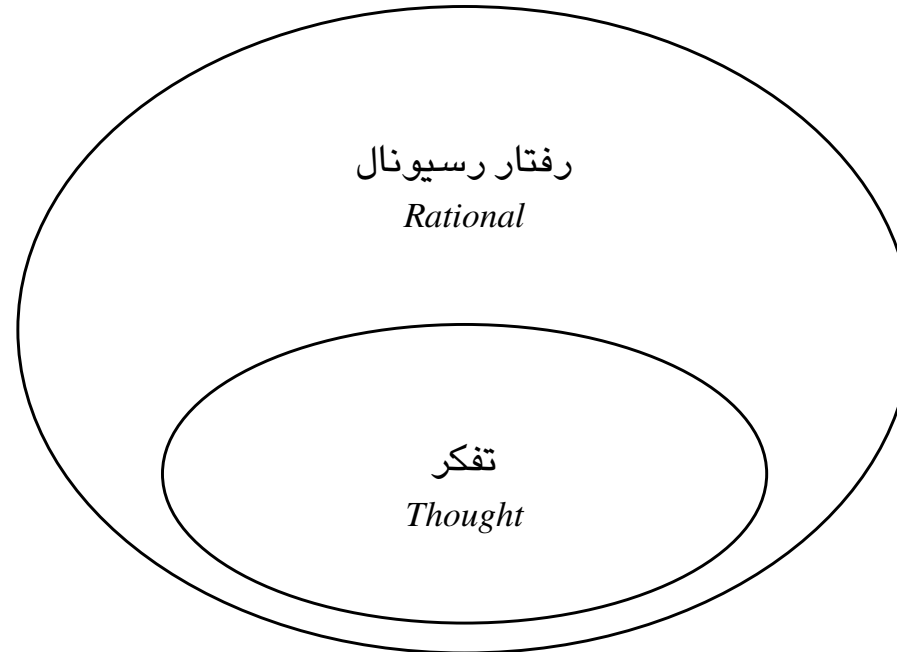
...	ایجاد و پیگیری اهداف <i>create and pursue goals</i>	وفاق‌یابی با تغییر <i>adapt to change</i>	استمرار در زمان طولانی <i>persist over a prolonged time</i>	درک محیط <i>perceive the environment</i>	عملکرد خودمختار <i>operate autonomously</i>
-----	---	---	---	--	---

عامل رسیونال

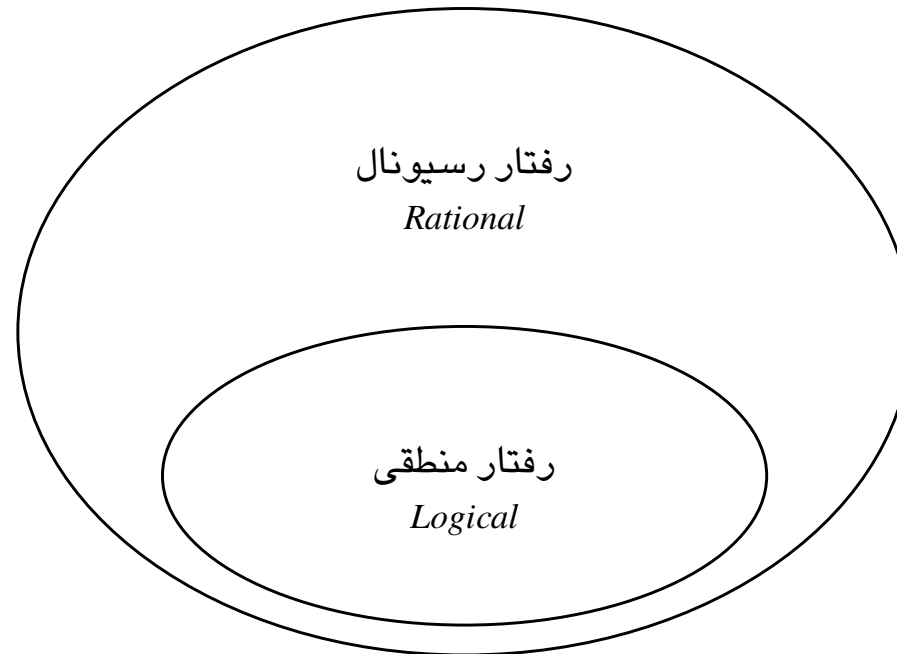
RATIONAL AGENT

عامل رسیونال (کننده‌ی کار خوب)	
در شرایط عدم اطمینان	در شرایط اطمینان
انجام کنش با بهترین برآمد مورد انتظار	انجام کنش با بهترین برآمد

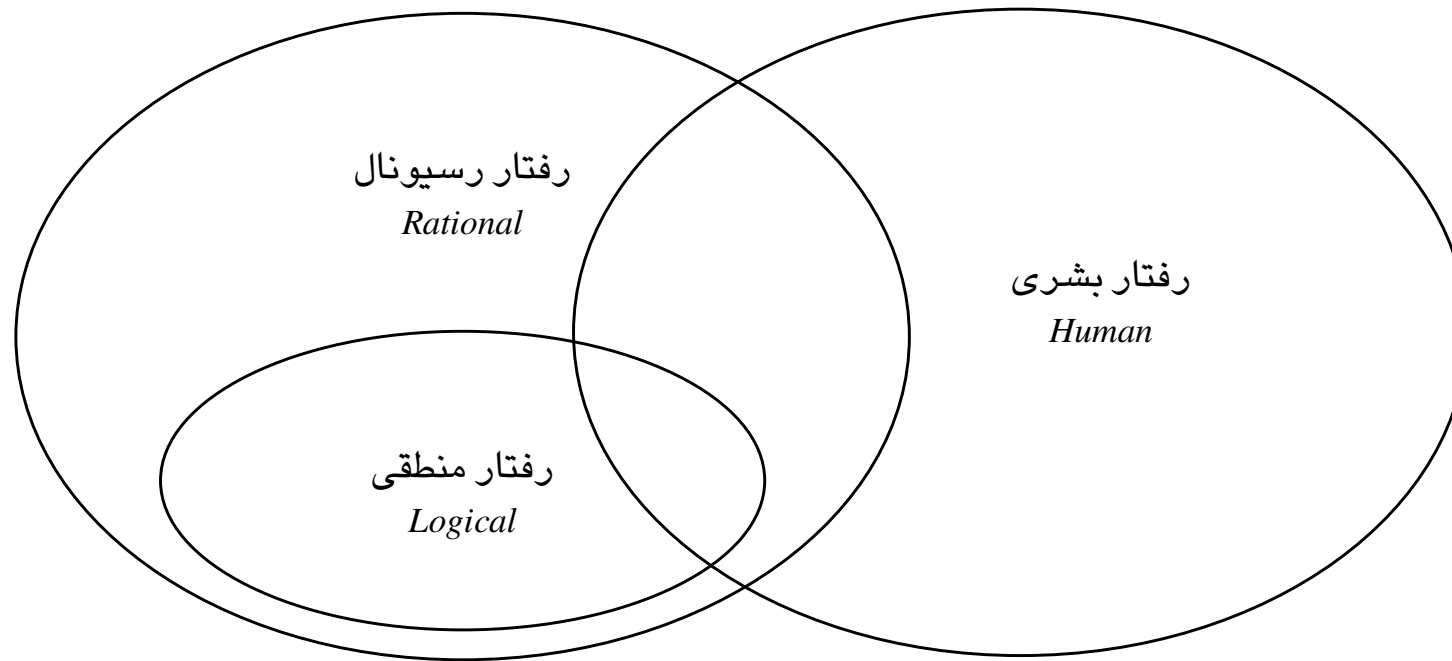
نسبت رفتار رسیونال با تفکر



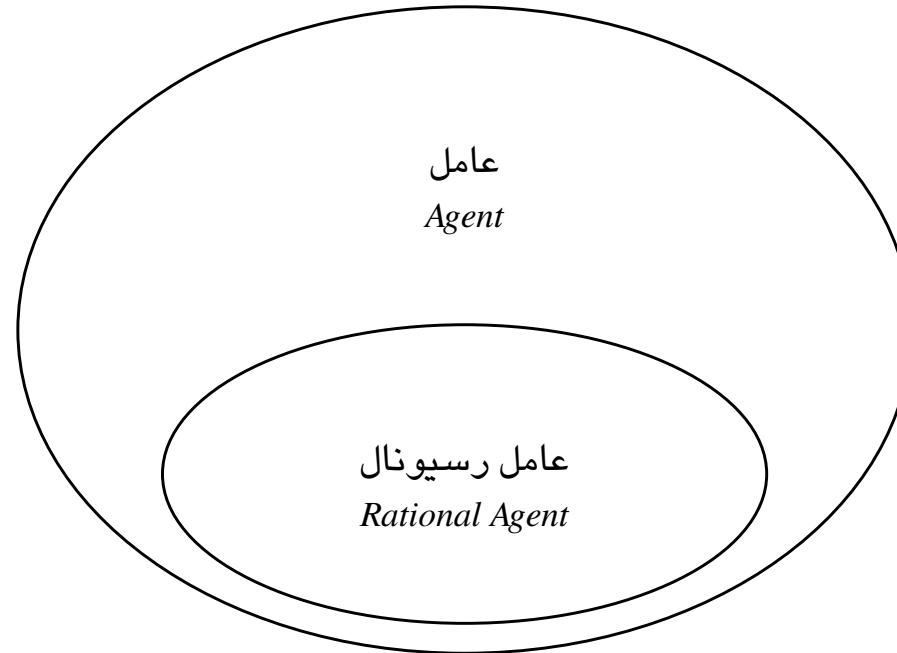
نسبت رفتار رسیونال با رفتار منطقی



نسبت رفتار رسیونال و رفتار منطقی با رفتار بشری



عامل رسیونال



عامل: موجودیتی که درک می‌کند و کنش انجام می‌دهد.

موضوع هوش مصنوعی: طراحی عامل‌های رسیونال

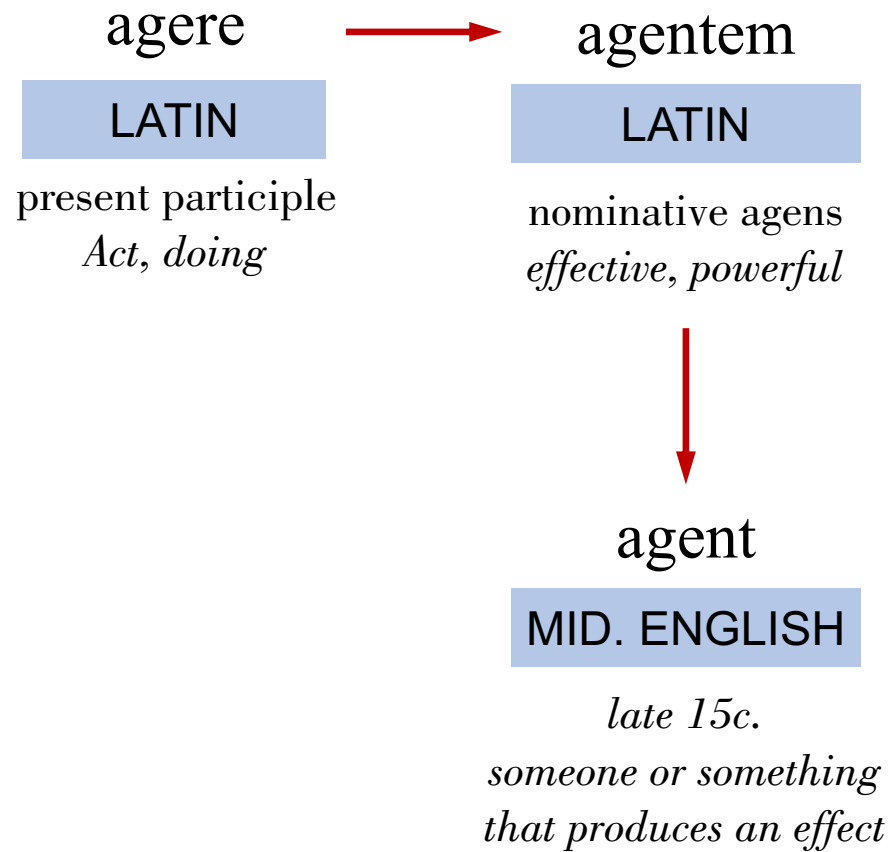
سیستم‌های چند عاملی

هوش مصنوعی و عوامل‌های هوشمند


۲

عامل

اتیمولوژی: Agent



عامل

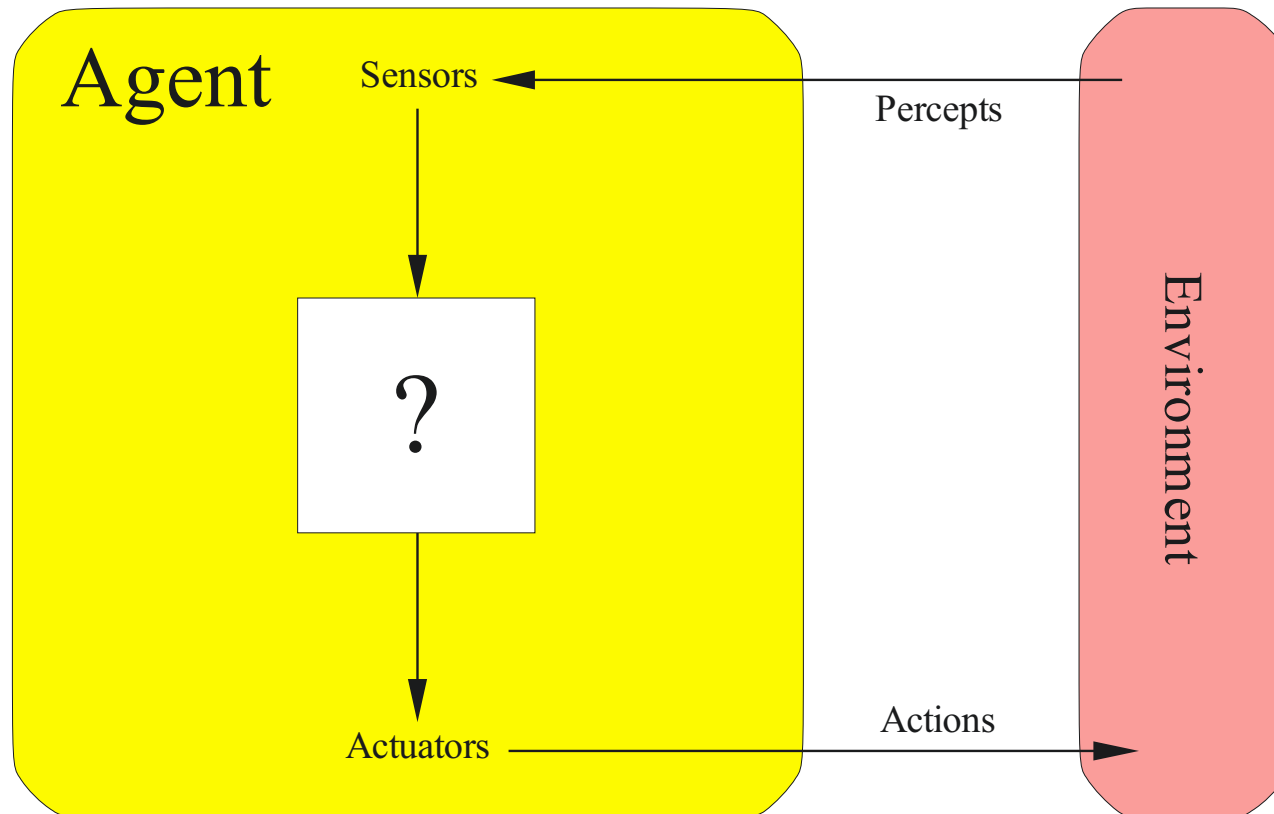
AGENT

عامل موجودیتی است که در محیط کار انجام می‌دهد.

عامل

AGENT

عامل چیزی است که محیط را از طریق حسگرهای خود درک می‌کند و سپس از طریق کنش‌گرهای خود روی آن کنش انجام می‌دهد.



عامل

مثال

حواس پنج‌گانه: چشم، گوش و ...	حسگر	عامل انسانی <i>Human agent</i>
دست و پا، زبان و ...	کنش‌گر	
دوربین، فاصله‌یاب مادون قرمز و ...	حسگر	عامل روبات <i>Robotic agent</i>
موتور و ...	کنش‌گر	
دنباله‌ای از بیت‌ها	حسگر	عامل نرم‌افزاری <i>Software agent</i>
دنباله‌ای از بیت‌های کد شده	کنش‌گر	

مفهوم **عامل** وسیله‌ای برای مطالعه‌ی هوش مصنوعی است.


تقسیم‌بندی اشیا به «عامل» و «غیرعامل» نادرست است.
بر اساس نگاه طراح هر چیزی می‌تواند یک «عامل» باشد.

ادراک و دنباله‌ی ادراکی

ادراک (percept)، ورودی‌های ادراکی عامل در هر لحظه‌ی داده شده است.

p

دنباله‌ی ادراکی (percept sequence)، تاریخچه‌ی کامل همه‌ی چیزهایی است که عامل درک کرده است.




انتخاب کنش در هر لحظه توسط عامل،
می‌تواند به کل دنباله‌ی ادراکی مشاهده شده تا آن لحظه وابسته باشد،
اما به هیچ چیزی که تا آن لحظه آن را درک نکرده است، وابسته نیست.

تابع عامل

AGENT FUNCTION

رفتار عامل، با **تابع عامل** توصیف می‌شود که هر دنباله‌ی ادراکی داده شده را به یک کنش نگاشت می‌دهد.



برنامه‌ی عامل

AGENT PROGRAM

برنامه‌ی عامل، تابع عامل را بر روی یک معماری فیزیکی پیاده‌سازی و اجرا می‌کند.



نسبت تابع عامل با برنامه‌ی عامل

پیاده‌سازی می‌کند

تابع عامل <i>Agent Function</i>	برنامه‌ی عامل <i>Agent Program</i>
انتزاعی - مجرد (abstract)	انضمامی - مجسم (concrete)
ریاضی	برنامه‌نویسی
ورودی: یک دنباله‌ی ادراکی	ورودی: ادراک لحظه‌ای
-	قابل اجرا روی یک معماری
ممکن یک تابع عامل، برنامه‌ی عامل نداشته باشد.	یک تابع عامل، می‌تواند چند برنامه‌ی عامل داشته باشد.

تعیین عامل‌ها

Must

کدام موجودیت **می‌باید**
به‌عنوان **عامل** دیده شود؟

May

کدام موجودیت **می‌تواند**
به‌عنوان **عامل** دیده شود؟

پاسخ: براساس تاثیر عامل‌ها بر معیار کارآیی

هوش مصنوعی و عامل‌های هوشمند

۳

عامل
هوشمند
(IA)

عامل رسیونال

RATIONAL AGENT

عامل رسیونال:

عاملی که رفتار **خوب** انجام می‌دهد.



تقریب اول: رفتار خوب؛
رفتاری که باعث **بیشترین موفقیت** عامل شود.



نیاز به روشی برای **اندازه‌گیری موفقیت**
(**معیار کارآیی**)

معیار کارایی

معیار خوب بودن

PERFORMANCE MEASURE

معیار کارایی

میزان موفقیت رفتار یک عامل را نشان می‌دهد.

«معیار ارزیابی با در نظر گرفتن پی‌آمدهای رفتار آن عامل»

هر عامل در یک محیط بر اساس ادراک‌هایی که دریافت می‌کند، یک دنباله از کنش‌ها تولید می‌کند؛ دنباله‌ی کنش‌های عامل، موجب دنباله‌ای از حالت‌های محیط می‌شود؛ اگر این دنباله‌ی حالت‌های محیط، مطلوب بود، آن‌گاه عامل به خوبی عمل کرده است.

مفهوم مطلوب بودن در معیار کارایی احصا می‌شود:
معیار کارایی هر دنباله از حالت‌های محیط را ارزیابی می‌کند.

تذکر: در معیار کارایی، حالت‌های محیط مهم است، نه حالت‌های عامل
یعنی معیار کارایی را بر اساس آنچه در محیط می‌خواهیم طراحی می‌کنیم،
نه بر اساس آنچه فکر می‌کنیم عامل باید انجام بدهد.

معیار کارآیی

ملاحظات

مقایسه‌ی معیار کارآیی عینی و ذهنی

معیار کارآیی عینی <i>Objective Performance Measure</i>	معیار کارآیی ذهنی <i>Subjective Performance Measure</i>
نظر محیط برای ارزیابی عامل (توسط طراح و سازنده‌ی عامل)	نظر شخصی خود عامل برای ارزیابی او
ثابت: غیر قابل تغییر توسط عامل	متغیر: قابل تغییر توسط خود عامل
معیار کارآیی بر اساس هدف انتخاب می‌شود	معیار کارآیی با نیت موفق‌تر شدن عامل انتخاب می‌شود
مزیت: نیازی به پرسش از خود عامل نیست	مشکل: ممکن است عامل نتواند پاسخ بدهد
مزیت: عامل نمی‌تواند بسادگی محیط را فریب بدهد.	مشکل: ممکن است عامل پاسخ گمراه‌کننده و اشتباه بدهد

مشخصات یک معیار کارآیی مناسب

- نباید عامل را به دلیل یک چیز غیر قابل درک جریمه کند.
- نباید عامل را به دلیل یک کنش غیر قابل انجام جریمه کند.
- نباید عامل را به دلیل یک پی‌آمد غیر قابل پیش‌بینی جریمه کند.
- باید ارزیابی عامل در طول مدت کار (+ اول + آخر کار) باشد.
- باید هر دوی فرآیند و نتیجه‌ی کار عامل را در نظر بگیرد.


یک معیار کارآیی ثابت برای همه‌ی وظیفه‌ها و همه‌ی عامل‌ها وجود ندارد:
طراح باید متناسب با شرایط، معیار کارآیی را تدبیر کند.

رسیونالیته

پارامترهای وابسته

RATIONALITY

رسیونالیته در هر زمان وابسته به چهار مورد است:			
۱	۲	۳	۴
معیار کارآیی <i>Performace Measure</i>	دانایی پیشینی <i>Prior Knowledge</i>	کنش‌ها <i>Actions</i>	دنباله‌ی ادراکی <i>Percept Sequence</i>
ضابطه‌ی موفقیت عامل	دانایی پیشینی عامل از محیط	کنش‌هایی که عامل قادر به انجام آنهاست.	دنباله‌ی ادراکی عامل تا آن زمان



عامل رسیونال

RATIONAL AGENT

یک عامل رسیونال

کنشی را انتخاب می‌کند که
مقدار مورد انتظار معیار کارآیی را
با داشتن دنباله‌ی ادراکی تا آن لحظه
ماکزیمم می‌کند.

عامل رسیونال


تعریف (راسل و نوروگ)

RATIONAL AGENT

یک عامل رسیونال

برای هر دنباله‌ی ادراکی ممکن
کنشی را انتخاب می‌کند که
انتظار دارد معیار کارآیی آن را ماکزیمم کند؛

بر اساس شواهدی که توسط دنباله‌ی ادراکی فراهم می‌شود و
آنچه دانایی درون‌سازی شده‌ی عامل است.



رسیونالیتة

RATIONALITY

پیامد کنش‌ها ممکن
است مورد انتظار
نباشد

آگاه از غیب

Clairvoyant

ادراکات ممکن است
همه‌ی اطلاعات
مربوط را فراهم نکند

همه‌چیزدان

Omniscient

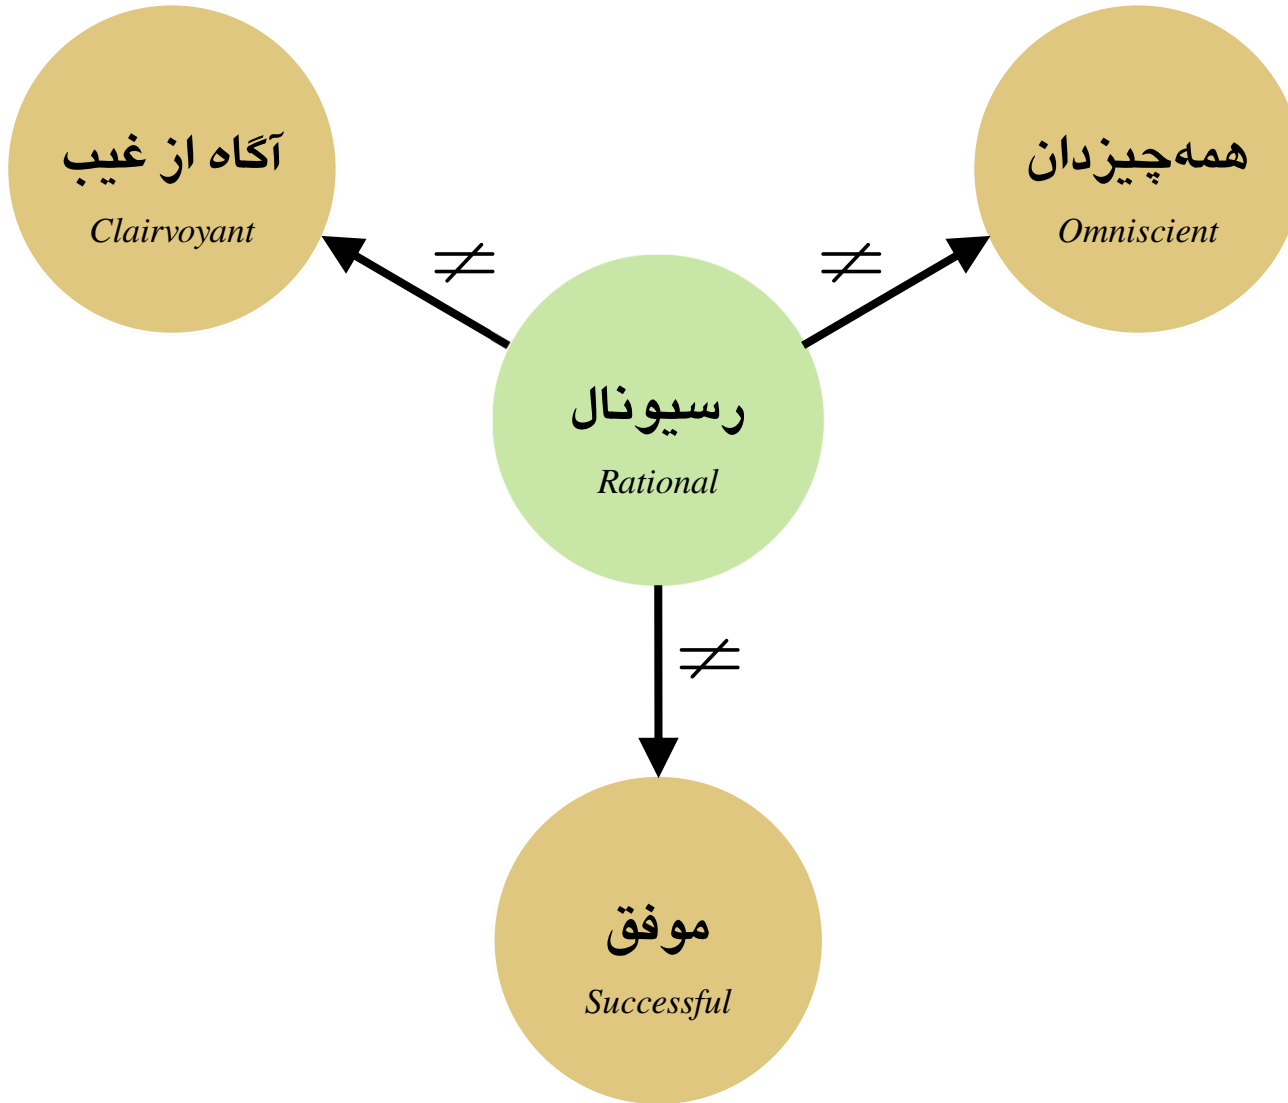
رسیونال

Rational

موفق

Successful

عامل ممکن است
شکست بخورد



تمایز رسیونالیته با کامل بودن

کامل بودن <i>Perfection</i>	رسیونالیته <i>Rationality</i>
ماکزیم‌سازی کارآیی واقعی (actual)	ماکزیم‌سازی کارآیی مورد انتظار (expected)
انجام بهترین کار ممکن	انجام بهترین کاری که توانسته است بفهمد
پیاده‌سازی غیر ممکن	پیاده‌سازی امکان پذیر

رسیونالیتة

ملزومات

عامل نباید رفتار غیر
هوشمندانه داشته باشد:
قبل از تصمیم‌گیری باید
اطلاعات کافی از محیط
جمع کند



یادگیری
Learning

یادگیری از تجربیات
و ادراک‌ها

رسیونال
Rational

خودمختاری
Autonomy

دانایی عامل مستقل از دانایی اولیه‌ی آن می‌شود؛
رفتار عامل توسط تجربه‌ی او تعیین می‌شود.

سیستم‌های چند عاملی

هوش مصنوعی و عوامل‌های هوشمند

۴

محیط

مشخص‌سازی محیط وظیفه

SPECIFYING THE TASK ENVIRONMENT

P	E	A	S
معیار کارآیی	محیط	کنش‌گرها	حسگرها
<i>Performace Measure</i>	<i>Environment</i>	<i>Actuators</i>	<i>Sensors</i>

مشخص‌سازی محیط وظیفه

مثال: دنیای جاروبرقی

SPECIFYING THE TASK ENVIRONMENT: THE VACUUM-CLEANER AGENT


P	E	A	S
معیار کارایی	محیط	کنش‌گرها	حسگرها
<i>Performace Measure</i>	<i>Environment</i>	<i>Actuators</i>	<i>Sensors</i>

برای هر مربع تمیز
در هر گام زمانی، یک
امتیاز مثبت
کلاً ۱۰۰۰ گام زمانی
طول عمر

نقشه‌ی محیط معلوم،
توزیع آشغال‌ها و
مکان اولیه‌ی عامل
نامعلوم

انجام کنش‌های
راست
چپ
مکش
هیچ

حسگر مکان
حسگر کثیفی مربع



مشخص‌سازی محیط وظیفه

مثال: تاکسی خودکار هوشمند

SPECIFYING THE TASK ENVIRONMENT: AUTOMATIC INTELLIGENT TAXI

P	E	A	S
معیار کارآیی <i>Performace Measure</i>	محیط <i>Environment</i>	کنش‌گرها <i>Actuators</i>	حسگرها <i>Sensors</i>
ایمنی رسیدن به مقصد فایده رعایت قانون راحتی ...	خیابان‌ها/ آزادراه‌ها ترافیک علایم راهنمایی عابرین پیاده آب و هوا ...	فرمان گاز ترمز بوق بلندگو/ نمایشگر ...	تصویر شتاب‌سنج درجه‌ها حسگرهای موتور صفحه‌کلید موقعیت‌سنج GPS ...

مشخص‌سازی محیط وظیفه

مثال: عامل خرید اینترنتی

SPECIFYING THE TASK ENVIRONMENT: INTERNET SHOPPING AGENT

P	E	A	S
معیار کارآیی <i>Performace Measure</i>	محیط <i>Environment</i>	کنش‌گرها <i>Actuators</i>	حسگرها <i>Sensors</i>
قیمت کیفیت مناسب بودن کارآمدی ...	سایت‌های وب حال و آینده فروشندگان خریداران ...	نمایش به کاربر دنبال کردن یک URL پر کردن فرم ...	خواننده‌ی صفحات HTML (متن، گرافیک، اسکریپت) ...

خصوصیات محیط‌های وظیفه

PROPERTIES OF TASK ENVIRONMENTS

مشاهده‌پذیر کامل <i>Fully Observable</i>		مشاهده‌پذیر جزئی <i>Partially Observable</i>
تک عاملی <i>Single-agent</i>		چند عاملی <i>Multiagent</i>
قطعی <i>Deterministic</i>	استراتژیک <i>Strategic</i>	اتفاقی <i>Stochastic</i>
مقطعی <i>Episodic</i>		دنباله‌ای <i>Sequential</i>
ایستا <i>Static</i>	نیمه‌پویا <i>Semidynamic</i>	پویا <i>Dynamic</i>
گسسته <i>Discrete</i>		پیوسته <i>Continuous</i>
شناخته‌شده <i>Known</i>		ناشناخته <i>Unknown</i>

خصوصیات محیط‌های وظیفه

مشاهده‌پذیر کامل یا مشاهده‌پذیر جزئی

مشاهده‌پذیر کامل *Fully Observable*

حسگرهای عامل
دسترسی به حالت
کامل محیط در هر
لحظه را به عامل
می‌دهند.

راحتی کار: عامل برای
دنبال کردن دنیا نیازی
به نگهداری حالت
داخلی ندارد.

مشاهده‌پذیر کامل به طور مؤثر *effectively fully observable*

حسگرهای عامل

همه‌ی جنبه‌های مربوط

به انتخاب کنش را

نشان می‌دهند.

(مربوط بودن وابسته به معیار کارآیی)

مشاهده‌پذیر جزئی *Partially Observable*

حسگرهای عامل
دسترسی به جزئی
از حالت محیط در هر
لحظه را به عامل
می‌دهند.

مثلا عدم وجود حسگر،
حسگرهای نادقیق،
حسگرهای نویزی

مشاهده‌ناپذیر *unobservable*

عامل هیچ حسگری ندارد.

خصوصیات محیط‌های وظیفه

تک عاملی یا چند عاملی

تک عاملی Single-agent

یک عامل به تنهایی در محیط عمل می‌کند.

چند عاملی Multiagent

چند عامل در محیط عمل می‌کنند:

همکارانه Cooperative

افزایش معیار کارایی
یک عامل باعث
افزایش معیار کارایی
عامل دیگر می‌شود.

مثال: گروه سرود

نیمه ...
Partially ...

مثال: محیط رانندگی:
جای پارک: رقابتی
اجتناب از تصادف: همکارانه

رقابتی Competitive

افزایش معیار کارایی
یک عامل باعث کاهش
معیار کارایی عامل
دیگر می‌شود.

مثال: بازی شطرنج

استفاده از دانایی عامل‌های دیگر

برقراری ارتباط
communication

اجتناب از مضرات پیش‌بینی‌پذیری

رفتار تصادفی‌شده
randomized behavior

رفتارهای رسیونال
خاص محیط‌های چندعاملی

کدام موجودیت می‌تواند به عنوان عامل دیده شود؟ ← هر چیزی که محیط را درک کند و روی محیط کنش انجام دهد.

کدام موجودیت می‌باید به عنوان عامل دیده شود؟ ← هر چیزی که برای ماکزیم‌سازی معیار کارایی‌اش، که به رفتار دیگری هم وابسته است، تلاش می‌کند.

خصوصیات محیط‌های وظیفه

قطعی یا اتفاقی

قطعی

Deterministic

حالت بعدی محیط توسط
● **حالت فعلی و کنش اجرا**
شده توسط عامل به طور
کامل تعیین می‌شود.

راحتی کار: عامل برای دنبال
کردن دنیا نیازی به نگهداری
حالت داخلی ندارد.

استراتژیک

Strategic

● محیط قطعی است، بجز در
مورد کنش سایر عامل‌ها

اتفاقی

Stochastic

● حالت بعدی محیط توسط
حالت فعلی و کنش اجرا
شده توسط عامل به طور
کامل تعیین نمی‌شود.

- محیط مشاهده‌پذیر جزئی
ممکن است اتفاقی به نظر برسد.
- عدم قطعیت در مورد برآمدها
برحسب احتمالات کمی می‌شوند.

نامطمئن

Uncertain

● محیطی که مشاهده‌پذیر
کامل یا قطعی نباشد.

غیرقطعی

Non-deterministic

● حالت بعدی محیط توسط **حالت فعلی و کنش**
اجرا شده توسط عامل به طور کامل تعیین نمی‌شود.

کنش‌ها با برآمدهای ممکن آنها مشخص می‌شوند،
بدون انتساب احتمال به آنها

خصوصیات محیط‌های وظیفه

مقطعی یا دنباله‌ای

مقطعی

Episodic

تجربه‌ی عامل قابل تقسیم به
مقطع‌های اتمیک است.

در هر مقطع، عامل یک ادراک
دریافت می‌کند و سپس یک کنش
واحد انجام می‌دهد.

مقطع بعدی به کنش‌های انجام
شده در مقاطع قبلی وابسته نیست.

انتخاب کنش در هر مقطع فقط
وابسته به همان مقطع است.

ساده‌تر است: عامل نیازی ندارد به
جلو فکر کند!

مثال: عمده‌ی وظایف طبقه‌بندی

دنباله‌ای

Sequential

تصمیم فعلی می‌تواند بر
همه‌ی تصمیم‌های آینده
تأثیر بگذارد.

کنش‌های کوتاه‌مدت می‌توانند
پی‌آمدهای بلندمدت داشته باشند.

مثال: شطرنج، رانندگی تاکسی

خصوصیات محیط‌های وظیفه

ایستا یا پویا

ایستا

Static

● اگر محیط نتواند در هنگام تأمل عامل تغییر کند.

محیط برای آن عامل، ایستا است.

ساده‌تر است: (۱) عامل نیازی ندارد در هنگام تصمیم‌گیری در مورد یک کنش به نگاه کردن ادامه دهد. (۲) عامل لازم نیست نگران گذر زمان باشد.

مثال: شطرنج معمولی

نیمه‌پویا

Semidynamic

● اگر خود محیط با گذر زمان تغییر نکند، اما امتیاز کارآیی عامل تغییر کند.

مثال: شطرنج با ساعت

پویا

Dynamic

● اگر محیط بتواند در هنگام تأمل عامل تغییر کند.

محیط برای آن عامل، پویا است.

محیط پویا به طور مداوم از عامل می‌پرسد که می‌خواهد چه کنشی را انجام دهد. اگر هنوز تصمیم نگرفته باشد، فرض می‌کند تصمیم گرفته است کاری انجام ندهد.

مثال: رانندگی تاکسی (سایر خودروها و عابرین در حین تصمیم‌گیری عامل، حرکت می‌کنند).

خصوصیات محیط‌های وظیفه

گسسته یا پیوسته

گسسته

Discrete

● مؤلفه‌های گسسته
در کار هستند.

مثال: شطرنج معمولی
(حالت، زمان، ادراک،
کنش)

پیوسته

Continuous

● مؤلفه‌های پیوسته
در کار هستند.

مثال: رانندگی تاکسی
(حالت، زمان، ادراک،
کنش)

تمایز پیوسته و گسسته: در مؤلفه‌های
حالت محیط، نحوه‌ی برخورد با زمان، ادراک‌ها و کنش‌های عامل

خصوصیات محیط‌های وظیفه

شناخته شده یا ناشناخته

شناخته شده

Known

برآمدها (یا احتمال برآمدها
در محیط اتفافی) برای همه‌ی
کنش‌ها داده شده است.

یک محیط شناخته شده می‌تواند
مشاهده‌پذیر جزئی باشد.

مثال: بازی کارت

تمایز میان محیط شناخته شده
و ناشناخته، همان تمایز بین
محیط مشاهده‌پذیر کامل و
جزئی نیست.

ناشناخته

Unknown

عامل باید یاد بگیرد که چگونه
عمل کند تا تصمیم‌های خوبی
بگیرد.

یک محیط ناشناخته می‌تواند
مشاهده‌پذیر کامل باشد.

مثال: بازی‌های ویدئویی جدید؛
صفحه‌ی بازی می‌تواند کل حالت بازی را نشان
بدهد، اما معلوم نیست دکمه‌ها چه کاری انجام
می‌دهند که با آزمایش معلوم می‌شود.

این خصوصیت، فقط به خود محیط برنمی‌گردد، بلکه
به حالت دانایی عامل (یا طراح آن) در مورد «قوانین فیزیک» محیط برمی‌گردد.

خصوصیات محیط‌های وظیفه

مثال‌هایی از محیط‌های وظیفه و مشخصه‌های آنها

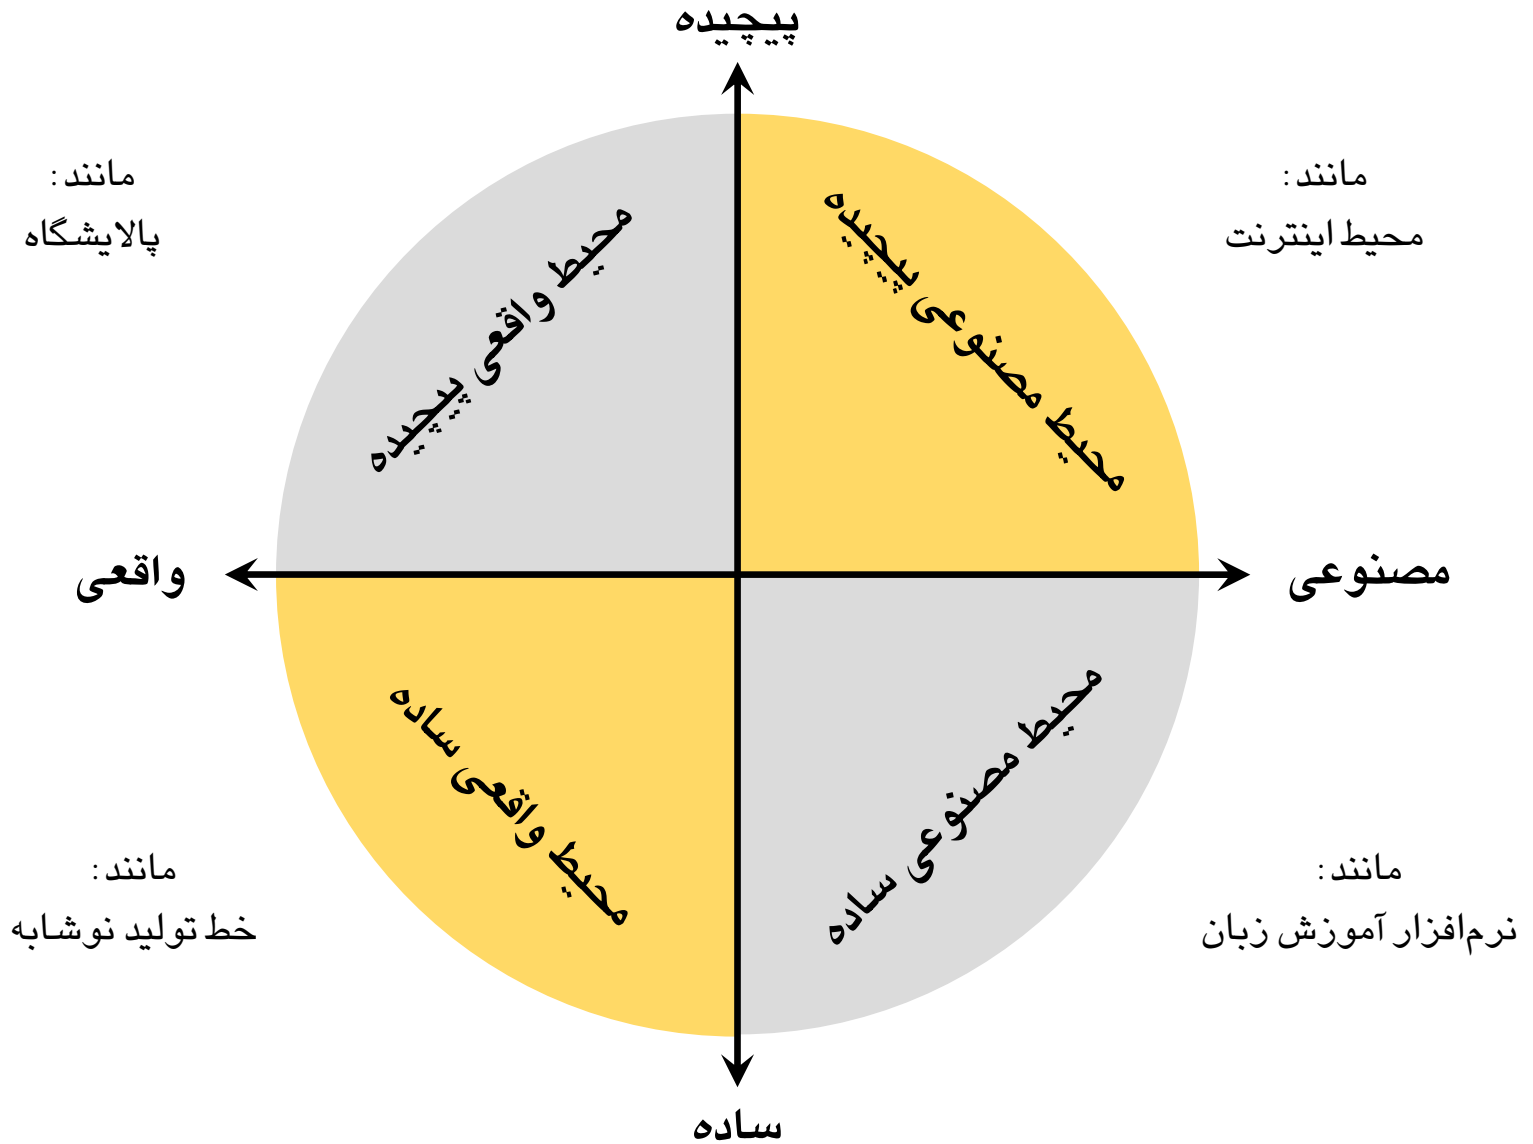
مشاهده‌پذیر؟	چندعاملی؟	قطعی؟	مقطعی؟	ایستا؟	گسسته؟	
کامل	چندعاملی	قطعی	دنباله‌ای	ایستا	گسسته	بازی شطرنج
کامل	چندعاملی	اتفاقی	دنباله‌ای	ایستا	گسسته	بازی مار و پله
جزئی	تک‌عاملی*	تاحدودی	دنباله‌ای	نیمه‌پویا	گسسته	خرید اینترنتی
جزئی	چندعاملی	اتفاقی	دنباله‌ای	پویا	پیوسته	رانندگی تاکسی
جزئی	تک‌عاملی	اتفاقی	دنباله‌ای	پویا	پیوسته	تشخیص پزشکی
جزئی	تک‌عاملی	اتفاقی	دنباله‌ای	پویا	پیوسته	کنترلر پالایشگاه

نوع محیط، روش طراحی عامل را مشخص می‌کند.

هر مجموعه از روش‌های هوش مصنوعی، برای طراحی عامل در نوع خاصی از محیط مناسب است.

انواع محیط

نسبت محیط ساده / پیچیده با محیط واقعی / مصنوعی




هوش مصنوعی و عوامل‌های هوشمند

۵

منابع

منبع اصلی



Stuart Russell and Peter Norvig,
Artificial Intelligence: A Modern Approach,
 4th Edition, Prentice Hall, 2020.

Chapters 1, 2

CHAPTER 1

INTRODUCTION

In which we try to explain why we consider artificial intelligence to be a subject most worthy of study, and in which we try to decide what exactly it is, this being a good thing to decide before embarking.

We call ourselves *Homo sapiens*—man the wise—because our **intelligence** is so important to us. For thousands of years, we have tried to understand *how we think and act*—that is, how our brain, a mere handful of matter, can perceive, understand, predict, and manipulate a world far larger and more complicated than itself. The field of **artificial intelligence**, or AI, is concerned with not just understanding but also *building* intelligent entities—machines that can compute how to act effectively and safely in a wide variety of novel situations.

Surveys regularly rank AI as one of the most interesting and fastest-growing fields, and it is already generating over a trillion dollars a year in revenue. AI expert Kai-Fu Lee predicts that its impact will be “more than anything in the history of mankind.” Moreover, the intellectual frontiers of AI are wide open. Whereas a student of an older science such as physics might feel that the best ideas have already been discovered by Galileo, Newton, Curie, Einstein, and the rest, AI still has many openings for full-time masterminds.

AI currently encompasses a huge variety of subfields, ranging from the general (learning, reasoning, perception, and so on) to the specific, such as playing chess, proving mathematical theorems, writing poetry, driving a car, or diagnosing diseases. AI is relevant to any intellectual task; it is truly a universal field.

1.1 What Is AI?

We have claimed that AI is interesting, but we have not said what it *is*. Historically, researchers have pursued several different versions of AI. Some have defined intelligence in terms of fidelity to *human* performance, while others prefer an abstract, formal definition of intelligence called **rationality**—loosely speaking, doing the “right thing.” The subject matter itself also varies: some consider intelligence to be a property of internal *thought processes* and *reasoning*, while others focus on intelligent *behavior*, an external characterization.¹

From these two dimensions—human vs. rational² and thought vs. behavior—there are four possible combinations, and there have been adherents and research programs for all

¹ In the public eye, there is sometimes confusion between the terms “artificial intelligence” and “machine learning.” Machine learning is a subfield of AI that studies the ability to improve performance based on experience. Some AI systems use machine learning methods to achieve competence, but some do not.

² We are not suggesting that humans are “irrational” in the dictionary sense of “deprived of normal mental clarity.” We are merely conceding that human decisions are not always mathematically perfect.

Intelligence

Artificial Intelligence

Rationality