

Convergence of Privacy and Transparency, Limitations of Artificial Intelligence Design

Mohammad Ali

Ashouri Kisomi * 

PhD of Philosophy of Art, Allameh Tabataba'i
University, Tehran, Iran

Abstract

This research aims to criticize the approach that considers the solution to the ethical challenges of artificial intelligence (AI) to be only in design and technical improvements. Some researchers consider the ethical challenges in AI to be convergent, which emerge with the advent of AI systems and are resolved with technical progress and improvements. In the discussions of the ethics of AI, issues such as privacy and transparency have been the focus of most studies. In the present research, using the analytical-critical method, the convergence between transparency and privacy in machine learning systems was investigated, and the approach that limits the resolution of ethical challenges to AI design was criticized. The research findings indicate that there is no convergence between the ethical challenges of AI. Additionally, by raising three challenges of quantification, technical limitations, and meta-ethical issues, the criticism of approaches that rely solely on design and technical improvements was addressed. The results also indicate that it is not possible to respond to the ethical challenges of AI only by relying on design, and there is a need to use other methods such as legislation or progress in other sciences in addition to attention to design.

Keywords: artificial intelligence ethics, privacy, transparency, opacity, ethical design.

* m_ashori@atu.ac.ir

How to Cite: Ashouri Kisomi, Mohammad Ali. (2024). Convergence of Privacy and Transparency, Limitations of Artificial Intelligence Design, *Hekmat va Falsafeh*, 20 (78), 45-73.

DIO: 10.22054/wph.2024.75680.2183

1. Introduction

One of the challenges in the ethics of artificial intelligence (AI) is the actual implementation of laws and human rights. Issues such as identifying legal responsibility, providing proof, etc. still lie ahead of us. Although significant efforts have been made in this direction, such as establishing the European Union's GDPR, many problems remain. Among the existing views on the ethics of AI, some believe that the solution to these problems should be sought in technical matters. For example, proponents of 'Internet Libertarianism' or 'Cyber Libertarianism' can be cited. These views, to some extent, are based on the assumption that technical solutions can solve the social problems created by AI systems. According to this approach, the ethical issues and challenges of AI are somewhat convergent. In other words, the emergence of AI brings about ethical issues; these problems are intensified during the development of AI systems (convergence in increasing ethical challenges); and finally, AI and its technical reforms solve these problems (convergence in resolving ethical challenges). On the contrary, the main goal of this research is to examine and investigate this view, focusing on the two ethical difficulties of privacy and transparency in AI systems.

To achieve the main goal of the research, the relationship and convergence of privacy and transparency in machine learning systems will be examined. Following the rejection of convergence, reasons will also be provided against approaches that consider the ethical challenges of AI in design and technical reforms. In line with reaching the intended goals, the research is divided into four sections. In the initial section, what we mean by AI and machine learning will be introduced. After clarifying the main concepts, the second section examines ethical approaches to privacy in the ethics of AI. The third section deals with transparency/opacity, its types, and its relationship with privacy. In the fourth section, after identifying the challenges ahead in the previous sections, the relationship between transparency and privacy is examined, and criticisms are presented.

Research Question(s)

1. In the context of machine learning systems, to what extent are the ethical considerations of privacy protection and transparency convergent?

2. Literature Review

Numerous studies have been conducted on the ethics of artificial intelligence and, more precisely, on machine learning systems, and a very rich and extensive body of research literature is forming. In this regard, privacy and opacity/transparency are topics that have repeatedly garnered the attention of philosophers. Some believe that without

transparency, privacy cannot be protected; as we will lack a rationale for the machine's judgments, which are considered essential for protecting privacy. Consequently, with increased opacity/decreased transparency, privacy will be more at risk.

3. Methodology

The current study employs an analytical-critical methodology to explore the nexus between transparency and privacy within machine learning systems. Furthermore, this study challenges the limited perspective that ethical issues in AI can be addressed only through the way AI systems are ethically designed.

4. Conclusion

Considering the objectives mentioned, the findings of this research are divided into two parts. In the first part, the results indicate that in the discussions on the ethics of artificial intelligence, there is no necessity for convergence between transparency/opacity and privacy. In other words, increased transparency does not guarantee the protection of privacy. It is noteworthy that if these two issues are considered convergent, the result could be the endangerment of privacy. Sometimes transparency and the protection of privacy in an AI system may improve together, but this is not a general rule and should not be interpreted as one strengthening the other. It was also determined that there are various methods to protect privacy in AI systems, and we do not always need transparency. These results implicitly support the idea that we should consider the ethical discussions of artificial intelligence as separate and non-convergent issues. This lack of convergence shows that we are dealing with significant issues, not just one ethical issue and its subsets. In the second part, the research results demonstrate that although, in many cases, technical solutions and design adjustments are effective, they face limitations in some situations and will not be a solution for all circumstances. Just as philosophical and ethical approaches that do not consider the various structures of artificial intelligence can lead to general analyses that often have no relation to the structures of AI; if we consider technical solutions as general solutions without regard to different conditions, we will again make a mistake in another way. In such situations, it is necessary to use other methods, such as legislation, advancements in other domains of science, along with ethical design, to overcome some of the existing limitations.



همگرایی حريم خصوصی و شفافیت، محدودیت‌های طراحی هوش مصنوعی

محمدعلی عاشوری کیسمی*



چکیده

هدف از این پژوهش نقد به رویکردی است که راهکار برطرف شدن چالش‌های اخلاقی هوش مصنوعی را محدود به طراحی و اصلاحات فنی می‌داند. برخی پژوهش‌گران چالش‌های اخلاقی در هوش مصنوعی را همگرا تلقی می‌کنند و معتقدند این چالش‌ها همانطور که با ظهور سیستم هوش مصنوعی پدید آمدند، با پیشرفت و اصلاحات فنی آن مرتفع خواهند شد. در مباحث اخلاقی هوش مصنوعی، موضوعاتی همچون حفاظت از حريم خصوصی و شفافیت در بیشتر پژوهش‌ها مورد توجه قرار گرفته است. در پژوهش حاضر با استفاده از روش تحلیلی-انتقادی، همگرایی میان شفافیت و حريم خصوصی در سیستم‌های یادگیری ماشین بررسی شده و رویکردی که رفع چالش‌های اخلاقی را به طراحی هوش مصنوعی محدود می‌داند به نقد گذاشته شده است. نتایج این بررسی نشان می‌دهد که همگرایی میان چالش‌های اخلاقی هوش مصنوعی وجود ندارد. همچنین با مطرح کردن سه چالش کمی‌سازی، محدودیت‌های تکنیکی و مباحث فرآخلاقی به نقد رویکردهایی که تنها بر طراحی و اصلاحات فنی متکی هستند پرداخته شد. نتایج این بخش نشان می‌دهد که نمی‌توان تنها با تکیه بر طراحی، به چالش‌های اخلاقی در هوش مصنوعی پاسخ داد و نیاز به استفاده از سایر روش‌ها مانند قانون‌گذاری و یا پیشرفت در سایر علوم در کنار توجه به طراحی وجود دارد.

واژه‌های کلیدی: اخلاق هوش مصنوعی، حريم خصوصی، شفافیت، کدری، یادگیری ماشین، طراحی اخلاقی.

۱. مقدمه

با گسترش استفاده از هوش مصنوعی^۱ مباحث اخلاقی آن مورد توجه فیلسوفان قرار گرفت. دسته‌ای از این مباحث اخلاقی بر اساس تصوراتی است که امروزه از لحاظ فنی امکان‌پذیر نیست (Hagendorff & Wezel, 2020)؛ اما بسیاری از آن‌ها، ممکن است در آینده به حقیقت پیوندد (Muller & Bostrom, 2016). زمانی که از هوش مصنوعی سخن به میان می‌آید عموماً پژوهش‌ها به ده مبحث اصلی اخلاقی تمرکز می‌کنند^۲: حریم خصوصی و نظارت^۳، دستکاری در رفتار^۴، کدری^۵ و شفافیت^۶، سوگیری در تصمیمات سیستم^۷، اثر متقابل انسان-ربات^۸، اتوМАSیون و اشتغال^۹، سیستم‌های خودمختار^{۱۰}، اخلاق ماشین^{۱۱}، عامل اخلاقی مصنوعی^{۱۲} و تکینگی^{۱۳} (Muller, 2021). این مباحث گاهی با یکدیگر تداخل پیدا کرده و نمی‌توان همواره مرز دقیقی میان آن‌ها مشخص کرد. این مباحث معمولاً در سیستم‌های مختلف هوش مصنوعی خود را نمایان می‌سازند. به عبارتی دقیق‌تر، مباحث اخلاقی فوق ممکن است در برخی سیستم‌های هوش مصنوعی دارای اهمیت بود و در برخی سیستم‌ها اصولاً چندان قابل تأمل نباشد^{۱۴}. همچنین، باید توجه داشت شکل بروز و

۱. Artificial Intelligence

۲. البته بسیاری از تاثیرات خارجی هوش مصنوعی کمتر مورد توجه قرار می‌گیرد و در پژوهش‌های جریان اصلی معمولاً به موضوعاتی پرداخته می‌شود که راهکارهای فنی برای آن‌ها وجود دارد (Hagendorff, 2022).

۲. Privacy and surveillance

۴. Manipulation of behavior

۵. Opacity

۶. Transparency

۷. Bias in decision systems

۸. Human-Robot interaction

۹. Automation and Employment

۱۰. Autonomous Systems

۱۱. Machine Ethics

۱۲. Artificial Moral Agents

۱۳. Singularity

۱۴. به عنوان مثال، اثرات متقابل انسان-ربات در یک سیستم نرم‌افزاری هوش مصنوعی دارای اهمیت نخواهد بود. یا در یک سیستم هوش مصنوعی ضعیف، مبحث تکینگی محلی از بحث پیدا نخواهد کرد.

توجه به هر کدام از این مباحث می‌تواند با توجه به سیستم‌های مشخص با یکدیگر متفاوت باشد^۱. در میان تکنیک‌های مختلف هوش مصنوعی، یکی از مهم‌ترین آن‌ها از نظر فیلسوفان و پژوهشگران اخلاق، «یادگیری ماشین»^۲ است، اما زمانی که از یادگیری ماشین سخن به میان می‌آید نیز تنها با یک شیوه یادگیری روبرو نیستیم (Bhatnagar, 2019). پژوهش‌های فراوانی در خصوص اخلاق هوش مصنوعی در یادگیری ماشین صورت گرفته است و ادبیات پژوهشی بسیار غنی و گسترده‌ای در حال شکل‌گیری است. در این میان حریم خصوصی و کدری/شفافیت از جمله مباحثی است که به کرات مورد توجه فیلسوفان قرار گرفته است. به صورت خلاصه کدری/شفافیت به مشخص بودن/نبودن روندی که سیستم به یک نتیجه مشخص می‌رسد اشاره دارد (Muller, 2021a). برخی معتقدند بدون شفافیت نمی‌توان از حریم خصوصی حفاظت کرد؛ چراکه توجیهی برای قضاوت‌های ماشین که لازمه حفاظت از حریم خصوصی است در دست نخواهیم داشت. بر این اساس، با افزایش کدری/کاهش شفافیت، حریم خصوصی بیشتر در خطر خواهد بود (ر. ک Muller, 2021; Franzoni, 2023 Barhamgi & Bertino, 2022؛ قبیل چالش‌های اخلاقی روبرو می‌شویم، یک راه کار استفاده از قوانین و مقررات است.

یکی از چالش‌هایی که در حوزه هوش مصنوعی و تکنولوژی‌های دیجیتال وجود دارد، اجرای واقعی قوانین است. مشکلاتی همچون شناسایی مسئولیت حقوقی، اثبات و محکمه‌ای صالح که بتوان در صورت قصور به آن مراجعه کرد و همچنین اجرایی کردن تصمیمات این محکمه همچنان پیش روی ما است. اگرچه در این مسیر تلاش‌های فراوانی همچون وضع مقررات عمومی حفاظت از داده اتحادیه اروپا^۳ و پیش از آن قانون حفاظت

۱. به عنوان مثال زمانی که از سوگیری در یک سیستم هوش مصنوعی نسبتاً ساده که تنها اطلاعات افراد محدودی را نگهداری کرده و آن را طبقه‌بندی می‌کند صحبت می‌کنیم با زمانی که از سوگیری در یک سیستم پیچیده بر پایه شبکه‌های عصبی که می‌تواند اطلاعات انسانی را از میان داده‌های فراوان به دست آورد سخن می‌گوییم، دامنه مبحث سوگیری بسیار متفاوت خواهد بود.

۲. Machine Learning

۳. The General Data Protection Regulation (GDPR)

از داده اتحادیه اروپا^۱ صورت گرفته است اما هنوز مشکلات بسیاری پابرجا است.^۲ در این شرایط بسیاری از شرکت‌ها محصولات دیجیتال را به دور از نگرانی‌های اخلاقی به آزمایش گذاشته و یا منتشر می‌کنند (R. K. Muller, 2021a).

در میان دیدگاه‌های موجود در خصوص اخلاق هوش مصنوعی، برخی بر این عقیده هستند که راه کار بر طرف شدن این مشکلات را باید در امور فنی جستجو کرد. به عنوان نمونه این دیدگاه‌ها می‌توان به طرفداران «لیرتریانیسم اینترنت»^۳ یا «لیرتریانیسم سایبر»^۴ اشاره کرد. این قبیل دیدگاه‌ها، بر اساس این فرض استوار شده‌اند که راه کارهای فنی می‌توانند مشکلات اجتماعی که سیستم‌های هوش مصنوعی پدید آورده‌اند را بر طرف کنند^۵ (Mozorov, 2013; White, 2014). در این راستا پژوهش‌های مختلفی نیز صورت گرفته که به صورت ضمنی می‌توان آن‌ها را در راستای تقویت این رویکرد در نظر گرفت (R. K. Lee et al., 2022; Liu et al., 2022; Sengan et al., 2022). بر اساس این رویکردها، مشکلات و چالش‌های اخلاقی هوش مصنوعی با یکدیگر نوعی همگرایی دارند. به عبارتی دیگر، با پیدایش هوش مصنوعی مشکلات اخلاقی به وجود می‌آیند، در طول توسعه هوش مصنوعی این مشکلات تقویت می‌شوند (همگرایی در به افزایش چالش‌های اخلاقی) و دست آخر هوش مصنوعی و اصلاحات تکیکی آن این مشکلات را بر طرف می‌کنند (همگرایی در رفع چالش‌های اخلاقی). در نقطه مقابل، هدف اصلی این پژوهش بررسی و نقد به این دیدگاه با تمرکز بر دو چالش اخلاقی حریم خصوصی و شفافیت در سیستم‌های

۱. 95/46/EC (Data Protection Directive)

۲. گرچه این مبحث از منظر حقوقی دارای ابعاد مختلفی است، اما در پژوهش حاضر قصد ما نه تمرکز بر جنبه حقوقی و سیاست‌گذاری بلکه تمرکز بر جنبه اخلاقی است. لذا از ورود به مباحث حقوقی اجتناب شده است و به دلیل اهمیت، این موضوعات را شایسته بحث‌های بیشتر در پژوهش‌های جداگانه می‌دانیم.

۳. Internet Libertarianism: این اصطلاح را می‌توان تحت عنوان اختیارگرایی اینترنت هم ترجمه کرد. اما از آنجایی که اصطلاح اختیارگرایی ممکن است به معانی دیگری نیز تعبیر شود، از واژه لیرتریانیسم در متن استفاده شده است.

۴. Cyber Libertarianism

۵. قابل توجه است که لیرتریانیسم اینترنت یا لیرتریانیسم سایبر اهدافی همچون آزادی و یا مقابله با پدرسالاری (Paternalism) را در فضای سایبر نیز دنبال می‌کنند (White, 2014). در پژوهش حاضر نیز تلاش بر این نیست که این دیدگاه‌ها به صورت همه جانبه مورد بررسی قرار گرفته، رد یا تایید شوند بلکه ما به بخش از این دیدگاه نقد خود را وارد خواهیم کرد که بر طراحی فنی تمرکز است.

هوش مصنوعی است که از تکنیک‌های یادگیری ماشین استفاده می‌کند. به منظور دستیابی به هدف اصلی پژوهش، ارتباط و همگرایی حریم خصوصی و شفافیت مورد بررسی قرار خواهد گرفت. پیرو ردمگرایی، دلایلی نیز در رد رویکردهای که چالش‌های اخلاقی هوش مصنوعی را در طراحی و اصلاحات فنی می‌داند ارائه خواهد شد. در این مسیر، از روش تحلیلی-انتقادی و توجه به ساختارهای هوش مصنوعی در یادگیری ماشین استفاده خواهیم کرد تا از ارائه تصویر ذهنی و غیرواقعی از این سیستم‌ها پرهیز شود. شایان ذکر است، اهمیت پژوهش حاضر در تمرکز بر دو مبحث مشخص در اخلاق هوش مصنوعی برای رد رویکرد یاد شده و بیان برخی از ایرادات به آن است که تاکنون به شکلی منسجم صورت نگرفته است. در راستای رسیدن به اهداف موردنظر، پژوهش به چهار بخش تقسیم شده است. در بخش ابتدایی، آن‌چه از هوش مصنوعی و یادگیری ماشین مراد می‌کنیم معرفی خواهد شد. پس از روشن شدن مفاهیم اصلی، در بخش دوم رویکردهای اخلاقی به حریم خصوصی در اخلاق هوش مصنوعی موردنظر می‌گیرد. در بخش سوم به بررسی مفهوم شفافیت/کدری، انواع و ارتباط آن‌ها با حریم خصوصی پرداخته می‌شود. در بخش چهارم و پس از مشخص شدن چالش‌های پیش‌رو در بخش‌های پیشین، ارتباط میان شفافیت و حریم خصوصی بررسی شده و انتقادات ارائه می‌شود.

۲. هوش مصنوعی

آغاز آن‌چه امروز به عنوان حوزه هوش مصنوعی شناخته می‌شود به کنفرانس دارپا^۱ در کالج دارتموث^۲ باز می‌گردد. البته سخن گفتن از هوش مصنوعی تاریخچه‌ای طولانی تر دارد^۳ (Brindsjord & Govindrajulu, 2016). در پژوهش حاضر مقصود ما از هوش

۱. DARPA

۲. Dartmouth

۳. برخی پیشینه روش شناختی هوش مصنوعی را به فیلسوفانی چون لایب نیتس، هابز و آکویناس باز می‌گردانند (Falsinski, 2016). البته به شکلی جدیدتر اندیشمندانی همچون تیورینگ به هوش مصنوعی توجه شایانی داشتند. تیورینگ آزمایشی مطرح کرد که به عنوان آزمایش تیورینگ (Turing Test) شناخته می‌شود. پرسش اوین بود که آیا ماشین می‌تواند از نظر زبانی غیرقابل تشخیص از انسان باشد؟ براساس این آزمایش، اگر یک انسان در یک اتفاق و یک کامپیوتر در اتفاق دیگری باشد، سپس سوالی مشابه به کامپیوتر و انسان داده شود، یک قاضی براساس پاسخ‌های دریافتی باید تشخیص دهد کدام پاسخ مربوط به انسان است. اگر قاضی در ۵۰ درصد موارد، تواند پاسخ انسان را از

مصنوعی، نوعی سیستم محاسباتی است که برای رسیدن به هدف یا اهداف مشخص رفتارهای «هوشمند» اتخاذ می‌کند. در اینجا «هوشمند»، الزاماً هوشمند بهمانند انسان هوشمند نیست. یک هوش مصنوعی ممکن است توانایی‌های محدودتر یا گسترده‌تری از یک انسان داشته باشد (Muller, 2021a). لذا در این پژوهش مقصود ما هوش مصنوعی به معنای عام نیست و بر هوش مصنوعی در معنای ضعیف متصرکر خواهیم بود.^۱

۲-۱. یادگیری ماشین

همان‌طور که پیش‌تر اشاره شد «یادگیری ماشین» یکی از تکنیک‌های مهم هوش مصنوعی است که موردنویجه فیلسفه‌ان قرار گرفته است. دانش یادگیری ماشین به مطالعه و بررسی الگوریتم‌ها^۲ و مدل‌هایی^۳ می‌پردازد که با «یادگیری» از «داده‌های ورودی» برای دستیابی به هدف یا اهداف مشخص طراحی می‌شوند. از منظر عملی، برخلاف سیستم‌هایی که از ابتدا برای رسیدن به یک هدف مشخص طراحی می‌شوند و با تکرار نتایج مشابه به دست می‌دهند، یادگیری ماشین این امکان را فراهم می‌آورد که معماری سیستم با استفاده از تکرار یک فرآیند، تغییر و تطبیق پیدا کند. فرآیندی که در آن تطبیق و تغییر صورت

پاسخ کامپیوتر تمیز دهد، آن‌گاه ماشین موفق به گذراندن آزمایش تیورینگ است (Turing, 1950). البته دکارت هم این موضوع را مطرح کرده بود. به عقیده دکارت اگر ماشینی وجود داشت که می‌توانست از نظر ظاهری و اعمال شبیه به انسان باشد دو راه برای تشخیص ماشین از انسان وجود دارد. براساس روش اول چنین ماشینی قادر نخواهد بود از گفتار و یا نشانه‌های دیگر مانند انسان به شیوه‌ای استفاده کند که منجر به خیر دیگران شود. طبق روش دوم اگر ماشین بتواند برخی از کارها را مانند انسان انجام دهد، این کار را از روی عقل انجام نمی‌دهد و در نتیجه نمی‌تواند تمامی اعمال را مشابه با انسان انجام دهد (Descartes, 1955: 116).

۱. به عنوان مثال راسل و نورویگ (۲۰۲۰) معتقدند هوش مصنوعی حوزه‌ای است در تلاش برای ساخت سیستمی که مانند انسان فکر/عمل کند. از آنجایی که اینگونه تعاریف، هوش مصنوعی در معنای قوی (Strong Artificial Intelligence) یا عام (Artificial General Intelligence) را به ذهن مبتادر می‌سازد و در زمان نگارش این پژوهش هنوز به چنین مرحله‌ای نرسیده‌ایم، از این قبیل تعاریف دوری شده است.

۲. Algorithms: از منظر تاریخی، آن‌چه امروز به عنوان الگوریتم می‌شناسیم ریشه در آثار خوارزمی دارد. پس از او لایب‌نیتس ایده محاسبات نمادین را که امروز جبر ریاضی‌ای می‌خوانیم را پروراند. بعدها جورج بول ایده لایب‌نیتس را گسترش داد و جبر بولی را اختراع کرد. دیویت هیلبرت اصول ریاضیاتی را توسعه داد و پایه‌های رسیدن به علوم کامپیوتر امروزی را فراهم کرد (Thomas, 2015: 30-35).

۲. Models

می‌گیرد را «آموزش^۱» می‌نامند؛ به عبارتی در یادگیری ماشین، «یادگیری» به ماشین آموزش داده می‌شود^۲ (El Naqa & Murphy, 2015). اکنون که حوزه مشخص پژوهش حاضر

۱. Training

۲. یادگیری ماشین را می‌توان ترکیبی از سه جز دانست: داده‌ها، مدل یا فضای فرضیه (Model – Hypothesis)، تابع ضرر (Loss function) و تصویر (Feature). در یادگیری ماشین از مجموعه‌های داده‌ها استفاده می‌کنیم. یک مجموعه داده‌ها از واحدهای اتمی اطلاعات، یا همان داده تشکیل می‌شود که ممکن است به شیوه‌های مختلفی ذخیره شده باشد. مجموعه داده‌ها ممکن است شامل متن، سیگنال‌های دریافتی یک حسگر، فریم‌های ویدئو یا هر چیز دیگری باشند. هر داده دو خصوصیت دارد: ویژگی (Feature) و برچسب (Label). به عنوان مثال مجموعه داده‌های یک تصویر می‌تواند شامل ویژگی‌هایی همچون رنگ، تیرگی و روشنی و غیره را شامل شود. برچسب می‌تواند مشخص کند که داده‌های تصویر مربوط به چیست، مثلاً یک فرد، یک گل و غیره است. از روی مجموعه داده‌ها ماشین مدل می‌سازد یا یک مدل از پیش ساخته را بهینه می‌کند و با استفاده از تابع ضرر مدل اصلاح می‌شود. در عمل ابتدا داده‌ها جمع آوری می‌شوند. از نظر آماری هر چه حجم داده‌ها بیشتر باشد برای یادگیری بهتر است. باید توجه داشت که نمی‌توان این حجم را بی‌نهایت در نظر داشت؛ چراکه منابع سیستم‌ها دارای محدودیت محاسباتی است. پس از جمع آوردی داده‌ها، آماده‌سازی داده (Data preparation) انجام می‌شود؛ به عنوان مثال ویژگی‌ها و برچسب‌ها ثابت می‌شود و یا ممکن است نیاز باشد داده‌ها را از جهت وجود سوگیری (Bias) بررسی کرد، و با داده‌ها به صورت اتفاقی مرتب شوند تا ماشین از روی ترتیب ثبت داده‌ها، در یادگیری دچار اشتباه نشود. گاهی در این مرحله داده‌ها به دو بخش تقسیم می‌شوند؛ معمولاً بخش اعظم آن‌ها برای یادگیری و بخش اندکی برای ارزیابی از هم جدا می‌شوند. ماشین از روی مجموعه داده‌ها به الگوهایی (Pattern) دست می‌یابد که به وسیله آن‌ها می‌تواند مدل بسازد یا یک مدل از پیش موجود را توسعه دهد. مثلاً از روی داده‌های تصاویر گل‌ها، ماشین این الگو را می‌یابد که تصاویر گل دارای برچسب گل و ویژگی رنگ قرمز است و این یک الگو اولیه از تصاویر گل است. از مجموع این الگوهای ماشین یک مدل از گل را به دست می‌آورد. مدلی که به عنوان مثال در یک نمودار خط دو بعدی ساده بتواند داده‌های تصاویر گل و سایر تصاویر را از هم جدا کند. با این حال مدل‌ها ممکن است دارای اشتباه و نیازمند اصلاحات باشند؛ در این مرحله تابع ضرر وارد می‌شود. تابع ضرر وظیفه بررسی و اصلاح مدل (فرضیه) را دارد. به عبارتی میان مدلی که ماشین از روی داده‌ها ساخته و داده‌های واقعی سنجش صورت می‌گیرد تا موفقیت مدل برای پیش‌بینی‌های درست مشخص شود. در ابتدا ممکن است پیش‌بینی‌های ماشین نادرست بوده و نیاز به اصلاح مدل باشد؛ لذا نیاز به تمرین، یادگیری و اصلاح مدل براساس اشتباهات وجود دارد. به زبان ساده ابتدا داده‌های آموزشی وارد مدل می‌شوند/مدل ساخته می‌شود، مدل پیش‌بینی کرده و پیش‌بینی مورد ارزیابی قرار می‌گیرد. داده‌ها به روزرسانی می‌شوند و مجدداً این روند آنقدر تکرار می‌شود تا یادگیری ماشین به مرحله‌ای برسد که پیش‌بینی‌های درست به دست دهد. سپس در مرحله ارزیابی، این روند با داده‌های ارزیابی سنجیده می‌شود. در این مرحله از داده‌های ارزیابی برای مدل استفاده می‌شود و در مرحله آزمون تنها موفقیت مدل برای پیش‌بینی بررسی می‌شود (Jung, 2022: 39-19). قابل توجه است که آموزش محدود به داده‌های آموزشی نیست و یک الگوریتم خوب یادگیری ماشین قادر است با پردازش داده‌های جدید و یادگیری از اشتباهات یک یادگیری مدام‌العمر

در هوش مصنوعی معرفی شد، نیاز است مباحث و چالش‌های اخلاقی پژوهش حاضر (حریم خصوصی و شفافیت/کدری) صریح‌تر مطرح شوند!

۳- حریم خصوصی و یادگیری ماشین

تعاریف گوناگون و متفاوتی برای «حریم خصوصی» ارائه شده و با گزاره‌هایی گوناگونی رو به رو هستیم. این گزاره‌ها عموماً در دو گروه گزاره‌های توصیفی و هنجاری دسته‌بندی می‌شوند. گزاره‌های توصیفی، به توصیف موقعیت‌ها و شرایطِ حریم خصوصی می‌پردازند؛ و گزاره‌های هنجاری به ارزش‌گذاری موقعیت‌ها، شرایط و محدودیت در استفاده از اطلاعات یا پردازش اطلاعات می‌پردازند. گزاره‌های هنجاری عموماً به حق اخلاقی غیرمطلق فرد برای کنترل و یا دسترسی به اطلاعات درباره خود، موقعیت‌هایی که دیگران می‌توانند درباره او اطلاعات کسب کنند و تکنولوژی‌هایی که می‌توانند اقدام به تولید، پردازش و یا انتشار اطلاعات او کنند می‌پردازند.

در رویکرد هنجاری، با سه دیدگاه اصلی درباره حریم خصوصی مواجه هستیم: تحويل گرا^۱، غیرتحويل گرا^۲ و خوش‌های^۳. تحويل گرایان معتقدند که ادعاهای مربوط به حریم خصوصی و ارزش‌های آن مربوط به ارزش‌ها و رویکردهای دیگر اخلاقی مانند امنیت، خودمختاری، دموکراسی، آزادی و غیره است.^۴ در مقابل غیرتحويل گرایان معتقدند که حریم خصوصی، ارزش ذاتی داشته و نباید آن را به موضوعات دیگر فروکاست.^۵ دسته

داشتہ باشد (El Naqa & Murphy, 2015). این روند برای تمامی روش‌های یادگیری ماشین به صورت مشابه نیست؛ گاهی روندها پیچیده‌تر و گاهی ساده‌تر است.

۱. در این پژوهش هرجا که از هوش مصنوعی یاد می‌شود تنها به روش‌ها و تکنیک‌های یادگیری ماشین اشاره داریم و نه سایر روش‌ها و تکنیک‌های دیگر هوش مصنوعی.
۲. Reductionist: گاهی به تقلیل گرا و فروکاهندگان ترجمه می‌شود.

۲. Non-Reductionist

۴. Cluster

۵. به عنوان نمونه‌ای از تحويل گرایی در حریم خصوصی می‌توان به پژوهش دیوید متیسون (۲۰۰۸) اشاره کرد که در آن رویکرد تحويل گرایی توزیعی معرفی می‌شود.
۶. به عنوان نمونه از غیرتحويل گرایی می‌توان به پژوهش بیت روسler (۲۰۰۴) اشاره کرد. او با نقد به دیدگاه‌هایی که تنها به فضای عمومی می‌پردازند و فضای خصوصی را به عنوان زیرمجموعه آن در نظر می‌گیرند، معتقد است که در نظام لیبرال-دموکراسی حریم شخصی یک ارزش اصلی است که نمی‌توان آن را به شیوه‌ی تحويل گرایانه فروکاست.

سوم که به عنوان رویکرد خوش‌های شناخته می‌شود بر این عقیده هستند که خوش‌های از قضایای اخلاقی درباره حریم خصوصی وجود دارد و هیچ مؤلفه اساسی واحدی در خصوص حریم خصوصی وجود ندارد.^۱ در طرف دیگر و در رویکرد توصیفی حریم خصوصی از منظر معرفتی مورد توجه قرار می‌گیرند. بر اساس این رویکرد، نداشتن حریم خصوصی به این معنا است که دیگران به اطلاعات خصوصی فرد دسترسی دارند^۲ (Van den Hoven et al., 2020).

زمانی که از حریم خصوصی در یادگیری ماشین سخن به میان می‌آید معمولاً به محافظت از داده‌ها^۳ و امنیت داده‌ها^۴ توجه می‌شود. از منظر فنی راه کارهای گوناگونی برای حفاظت از داده‌ها و امنیت آن‌ها وجود دارد. از جمله این راه کارها می‌توان به طراحی ایمن^۵، کمینه‌سازی داده‌ها^۶، کنترل دسترسی^۷ و اطلاع‌رسانی اشاره کرد (Jobin et al., 2019). در گذشته تصور بر این بود که اگر داده‌ها توسط ماشین پردازش شوند و مستقیماً در دسترس افراد قرار نگیرند، می‌توان بیشتر از حریم خصوصی محافظت کرد. اما امروزه می‌دانیم که دسترسی ماشین به داده به معنای حفاظت از حریم خصوصی نیست (Muller, 2009) و یک واقعیت فنی در این است که بدون وجود داده‌ها نیز نمی‌توان ماشین را آموزش داد.

۱. در خصوص رویکرد خوش‌های پژوهش‌های گوناگونی صورت گرفته است. به عنوان مثال هلن نیسبنام (۲۰۰۴) پس از نقد به نظارت عمومی در ایالات متحده معتقد است این امر حق حفظ حریم خصوصی را نقض می‌کند. او استدلال می‌کند که برای حفاظت کافی از حریم خصوصی در خصوص نظارت عمومی، باید به هنجارهای زمینه‌ای خاصی توجه کرد که تنها مستلزم جمع‌آوری و انتشارات اطلاعات مناسب با زمینه مورد نظر باشد.

۲. به عنوان مثال مارتین بلاو (۲۰۱۳) استدلال می‌کند که حریم خصوصی باید در قالب معرفتی در ک شود. او معنای داشتن (درجاتی از) حریم خصوصی را این می‌داند که دیگران روابط معرفتی مهمی در موضوعاتی که فرد مایل به محرومانه نگاه داشتن آن‌ها است ندارند. وی حریم خصوصی را یک رابطه سه‌گانه میان یک سوژه (S)، مجموعه‌ای از گزاره‌ها (P) و افراد/فرد دیگر (O) می‌داند. به عقیده وی، زمانی از حریم خصوصی کامل برخوردار خواهد بود که O دسترسی معرفتی به P نداشته باشد. در مقابل اگر O بیشترین دسترسی معرفتی را با P داشته باشد S حریم خصوصی ندارد.

۳. Data protection

۴. Data security

۵. Privacy by design

۶. Data minimization

۷. Access control

در میان انواع رویکردهایی که به آن‌ها اشاره شد، بیشتر پژوهش‌گران اخلاق هوش مصنوعی، رویکرد خوش‌های از عناصری مانند «رضایت آگاهانه» را برای مطالعه یادگیری ماشین اتخاذ می‌کنند^۱. عقیده آن‌ها بر این است که این رویکرد، کمک می‌کند که یک عامل انسانی قادر به تصمیم‌گیری و عمل موجه در برابر تصمیمات و خروجی‌های ما شین باشد (Muller, 2021: 18). لذا ما نیز به بررسی رویکرد خوش‌های و عنصر رضایت آگاهانه در مباحث آتی تمرکز خواهیم کرد.

۴. کدری یادگیری ماشین در برابر حریم خصوصی

دومین مبحث اخلاقی پژوهش حاضر، کدری/شفافیت است. با تولید وسیع داده‌ها و اهمیت یافتن «اخلاق داده‌ها» و «اخلاق کلان داده‌ها»^۲ توجه فیلسوفان به موضوع شفافیت/کدری در اخلاق هوش مصنوعی جلب شد (Muller, 2021a). شفافیت/کدری را می‌توان در معنای گوناگون و ابعاد مختلفی موردنبررسی قرار می‌گیرد. در اینجا مقصود از شفافیت مشخص بودن روند رسیدن ماشین به یک نتیجه برای انسان و در مقابل کدری، عدم مشخص بودن این روند است^۳. در یادگیری ماشین ما با طیفی از کدری/شفافیت روبرو هستیم و می‌توان سه نوع کدری را از یکدیگر تمیز داد: کدری کم‌عمق^۴، کدری استاندارد^۵ و کدری عمیق^۶ (Muller, 2021: 18). با توجه تفاوت اشکال مختلف کدری در یادگیری ماشین، برای بررسی دقیق‌تر لازم خواهد بود به صورت مجزا به آن‌ها بپردازیم.

۱-۴. کدری کم‌عمق

در سیستم‌های تصمیم‌گیری خودکار و سیستم‌های پشتیبان که از هوش مصنوعی استفاده

۱. برای مشاهده نمونه این پژوهش‌ها رجوع کنید به (Muller, 2021).

۲. Data ethics

۳. Big data ethics

۴. به عنوان مثال مقصود ما شفافیت در نحوه جمع‌آوری داده‌ها، برچسب‌گذاری، بررسی از جهت وجود سوگیری (Bias) در آن‌ها و موارد مشابه دیگر نبوده و شایسته است در پژوهش‌های دیگر مورد توجه پژوهشگران قرار گیرند.

۵. Shallow opacity

۶. Standard opacity

۷. Deep opacity

می‌کنند، افرادی که به سیستم دسترسی دارند (متخصصان)، ممکن است قادر باشند از علت و روند رسیدن به تصمیمات مطلع شوند و اصطلاحاً سیستم برای آن‌ها «شفاف» باشد. در طرف مقابل افرادی که سیستم از داده‌های آن‌ها استفاده می‌کند (غیرمتخصص)، از دلیل و شیوه تصمیم‌گیری نامطلع بوده و سیستم برای آن‌ها «کدر» است. گزارش برخی پژوهش‌ها حاکی از آن است که این سیستم‌ها بخشی از «ساختارهای قدرت^۱» هستند (ibid:19).

برای روشن شدن این سطح از کدری ذکر یک مثال مفید خواهد بود. فرض کنید یک فرد نیازمند پیوند عضو (R) و نفر اول در لیست انتظار دریافت عضو است. فردی دیگر (G) می‌خواهد عضو خود را اهدا کند. احتمالاً عضو باید به فرد اول لیست انتظار، یعنی R برسد. در سیستم‌های هوش مصنوعی داده‌های افراد اهدا کننده و دریافت کننده با جزئیات مختلف ثبت می‌شوند. در این شرایط R متوجه می‌شود که فردی قصد اهدای عضو دارد، اما R هیچ اطلاعات شخصی و حتی نام G را نمی‌داند و اهدا به صورت ناشناس صورت می‌گیرد. سیستم (M) با توجه به بررسی داده‌ها به این نتیجه می‌رسد که عضو اهدایی نباید به نفر اول لیست انتظار برسد (C)، چراکه برخی داده‌های پرونده پزشکی R نشان می‌دهد عضو اهدایی با توجه به شرایط او مناسب نیست. در این شرایط فرد دیگری که داده‌های پرونده او با عضو اهدایی تناسب دارد انتخاب شده و عضو به او پیوند می‌شود. با اینکه M از روی داده‌هایی R تصمیم‌گیری کرده است، علت این تصمیم‌گیری برای R نامشخص بوده و به عبارتی کدر است. حال متخصص صینی (S) که به سیستم دسترسی دارند، ممکن است بتوانند از علت تصمیم‌گیری و داده‌های R و G مطلع شوند.

به صورت خلاصه:

۱- از داده‌های R استفاده می‌کند و به نتیجه C می‌رسد.

۱. Power Structure: در اینجا ساختارهای قدرت به معنای ایجاد فرآیندهایی است که فرصت را برای مشارکت انسانی در تصمیم‌گیری محدود کرده و شرایط این محدودیت را به آنها تحمیل می‌کنند که این موضوع بیشتر در مباحث سیاست هوش مصنوعی مورد توجه قرار می‌گیرد (Danaher, 2016: 245). در این سیستم‌ها معمولاً امکان مشارکت در تصمیم‌گیری برای افرادی که سیستم از داده‌های آن‌ها استفاده می‌کند محدود می‌شود. این سیستم‌ها با ساختارهای مشخصی از دسترسی طراحی می‌شوند. افرادی که سیستم از داده‌های آن‌ها استفاده می‌کند در اینکه این ساختارها چگونه طراحی شوند یا دسترسی‌ها تغییر کنند معمولاً انتخابی ندارند (رج. Muller, 2021). برای مثال رجوع کنید به (Muller, a2021؛ Muller, 2021؛ Diakopoulos 2015)

۲- از C مطلع می شود اما از علت رسیدن M به C اطلاعی ندارد و درنتیجه M برای R کدر است.

۳- از S مطلع می شود و می تواند مطلع شود چگونه M به C رسیده است و درنتیجه M برای S شفاف است.

۴- داده های R و G ممکن است در دسترس S قرار بگیرد.

همان طور که در ابتدای این بخش مطرح شد چنین سیستمی برای فردی که سیستم از داده های او استفاده می کند (R) کدر است. در این حالت، سیستم برای فردی که به سیستم دسترسی دارد (S) شفاف است. در چنین سیستمی ساختارهای قدرت هستند که رضایت آگاهانه و شفافیت را تعیین می کنند. به عبارتی دیگر، ساختار قدرت تعیین می کنند که سیستم برای M شفاف باشد یا خیر و حریم خصوصی او حفظ شود یا خیر. در این سطح، محدودیت ها یا تأثیرات ذاتی هوش مصنوعی ما را با چالش های اخلاقی روبرو نکرده بلکه طراحی و سیاست گذاری تعیین کننده است. پس به صورت خلاصه می توان این طور گفت که در شفافیت کم عمق، این هوش مصنوعی نیست که مسئله شفافیت و حفاظت از حریم خصوصی را پدید می آورد و این موضوعات به ساختارهای قدرت بازمی گردند.

۴- کدری استاندارد یا جعبه سیاه

برخی از تکنیک های یادگیری ماشین، سیستم ها مشابه شبکه های عصبی^۱ طراحی می شوند.

۱- **Artificial Neural Networks (ANN)**: این شبکه ها از چند لایه تشکیل می شوند؛ یک لایه ورودی (Input Layer)، یک لایه خروجی (Output Layer) و یک یا چند لایه پنهان (Hidden Layer) که میان لایه ورودی و خروجی قرار می گیرند. زمانی که بیش از یک لایه میانی وجود داشته باشد به آن شبکه عصبی عمیق (Deep Neural Network) و به روش یادگیری ماشین، یادگیری عمیق (Deep Learning) گفته می شود. ارتباط داده های بین لایه ها ممکن است از یک جهت باشد که از این روش در سیستم های پیش خور (Feed-forward) استفاده می شود و یا ممکن است این ارتباط در جهت های مختلف صورت بگیرد که از آن در سیستم های بازگشتی (Recurrent) استفاده می شود. این شبکه های عصبی ماشین از طریق یک سیستم باز خورد، خروجی ها را براساس داده های ورودی تغییر می دهند تا ماشین یاد بگیرد (Worden et al., 2023).

یادگیری این شبکه‌ها به سه شیوه تقسیم‌بندی می‌شوند^۱: یادگیری ناظارتی^۲، نیمه‌ناظارتی^۳ و غیرناظارتی^۴ (Muller, 2021: 19). البته در بسیاری از سیستم‌ها، این شیوه‌ها در کنار

۱. در برخی از شیوه یادگیری در چهار دسته یادگیری ناظارتی، غیرناظارتی، نیمه ناظارتی و تقویتی (Reinforcement) طبقه‌بندی (Bhatnagar, 2019: 276) و تحت عنوان پارادایم (Paradigms) یادگیری ماشین نامیده می‌شوند. البته برخی نیز تعداد پارادایم‌ها را تا ۱۰ مورد قابل تقسیم‌بندی می‌دانند (Emmert-Streib & Dehmer: 2022). قابل توجه است که بیشتر مواقع روش نیمه‌ناظارتی و تقویتی را در یک دسته قرار داده و سه پارادایم اصلی برای یادگیری ماشین در نظر گرفته می‌شود (Muller, 2021: 19) که ما نیز همین رویکرد را دنبال می‌کنیم.
۲. Supervised: در شیوه یادگیری ناظارتی، داده‌های آموزشی برچسب گذاری می‌شوند. به عبارتی در این شیوه، هر داده آموزشی بر جسبی دارد که آن را به یک خروجی مشخص مرتبط می‌کند (4). برچسب گذاری عموماً توسط عوامل انسانی صورت می‌گیرد. در این شیوه یادگیری، ماشین به دنبال یافتن فرضیه (مدلی) با تقلید از داده‌های آموزشی است. در حقیقت در مسیر یادگیری برچسب‌های داده‌های آموزشی، به نوعی راهنمای ماشین، برای یافتن فرضیه هستند. آن‌ها به ماشین نشان می‌دهند که کدام داده مربوط به کدام خروجی است (Jung, 2022: 12). به صورت کلی، دو نوع یادگیری ناظارتی وجود دارد: طبقه‌بندی (Classification) و رگرسیون (Regression). زمانی که مجموعه داده‌ها، شامل داده‌هایی است که از یکدیگر گسته هستند، از شیوه یادگیری ناظارتی و الگوریتم‌های طبقه‌بندی استفاده می‌شود. زمانی که مجموعه داده‌های ما، داده‌های عددی باشد از الگوریتم‌های رگرسیون استفاده می‌شود. با عنایت به اینکه در شیوه این شیوه برچسب گذاری توسط عوامل بیرونی، انجام می‌شود این روش را ناظارتی می‌نامیم (Kalita, 2022: 5-6).
۳. Semi-supervised: در خصوص یادگیری تقویتی یا نیمه‌ناظارتی دو دیدگاه مختلف وجود دارد. برخی عقیده دارند که یادگیری تقویتی، شباهی به یادگیری ناظارتی و غیرناظارتی ندارد؛ و در مقابل برخی معتقدند یادگیری تقویتی برخی از ویژگی‌های هر دو شیوه را دارد (Kalita, 2022: 7). یادگیری تقویتی (RL) تا حدودی مشابه شرطی‌سازی ابزاری (instrumental conditioning) در فیزیولوژی است. در شرطی‌سازی ابزاری، حیوانات ارتباط بین محرك و پاسخ را یاد می‌گیرند؛ به گونای که با توجه به یک محرك یا حالت محیطی، حیوان پاسخ یا عملی را امتحان می‌کند. اگر نتیجه پاسخ برای یک محرك مشخص ثابت باشد، ارتباط بین محرك و پاسخ تقویت می‌شود. در حقیقت ایده پارادایم یادگیری تقویتی این است که ماشین از طریق فرآیندی مشابه آزمون و خطا یاد بگیرد (Rolf et al., 2022: 4).
۴. Unsupervised: در یادگیری ماشین، گاهی نیاز نیست که از برچسب گذاری برای راهنمایی ماشین استفاده شود. در این شیوه، یادگیری یک فرضیه (مدل)، براساس ساختار ذاتی داده‌ها صورت می‌گیرد (Jung, 2022: 13). در حقیقت با توجه به اینکه برچسب گذاری در این روش استفاده نمی‌شود، یادگیری بدون عامل خارجی ناظر انجام می‌شود و به همین دلیل به آن یادگیری غیرناظاری گفته می‌شود (Kalita, 2022: 5-6). یادگیری غیرناظارتی شامل متدهای مختلفی است که میان آن‌ها می‌توان با متدهای خواهش‌بندی و روش‌های یادگیری ویژگی اشاره کرد (Jung, 2022: 13). در یادگیری غیرناظارتی داده‌های ورودی بسیار بالاهمیت خواهند بود؛ چراکه مثلاً اگر داده‌ها دارای سوگیری باشند،

یکدیگر به کار می‌روند^۱ (Emmert-Streib & Dehmer, 2022).

در شیوه یادگیری ناظری، ناظر/ناظران به ماشین می‌گویند آیا خروجی/پیش‌بینی ماشین درست است یا خیر. در روش نیمه ناظری ناظر/ناظران به ماشین نمی‌گویند کدام خروجی/پیش‌بینی صحیح یا غلط است، بلکه اهداف اصلی‌تر به آن گفته می‌شود به عنوان مثال از ماشین رسیدن به نتیجه به جای شیوه رسیدن به نتیجه خواسته می‌شود. در روش غیرناظری، هیچ بازخوری به ماشین داده نمی‌شود که آیا یک الگو درست است یا خیر و ماشین بر اساس ساختار ذاتی داده‌ها به یک مدل نهایی می‌رسد. با استفاده از این تکنیک‌ها ماشین قادر به یافتن الگوها از داده‌ها و رسیدن به مدل خواهد بود. متخصصین ماشین‌هایی که از روش غیرناظری استفاده می‌کنند، اگرچه الگوها و داده‌ها را مشاهده می‌کنند، اما نمی‌دانند چطور ماشین این الگوها را به دست آورده است. در این شیوه یادگیری، خروجی برای فرد غیرمتخصص و متخصصین «کدر» خواهد بود^۲. البته باید توجه داشت میزان کدر بودن برای متخصص و غیرمتخصص در یک سطح نیست و یک متخصص ممکن است پس از بررسی بتواند علت تصمیم گیری ماشین را تا حدودی بیابد (Muller, 2021: 19). اگر این موضوع را با کدری کم عمق مقایسه کنیم مشاهده می‌شود که تفاوت در این است که در کدری کم عمق، روند رسیدن به خروجی ممکن است برای افراد غیرمتخصص «کدر» و برای متخصص «شفاف» باشد؛ اما در کدری استاندارد روند رسیدن به خروجی برای متخصص و غیرمتخصص با درجات مختلفی کدر است.

برای برطرف شدن کدری استاندارد در سیستم‌هایی که از روش غیرناظری استفاده می‌کنند، می‌توان از هوش مصنوعی درون‌نمای^۳، استفاده کرد و شفافیت را افزایش داد. هدف از هوش مصنوعی درون‌نما به وجود آوردن امکان درک عوامل چرازی تصمیم گیری‌های

یادگیری و مدل دارای سوگیری خواهد بود. اگرچه مبحث سوگیری در موضوع شفافیت دارای اهمیت است، اما با توجه به اینکه در راستای اهداف و پرسش‌های پژوهش حاضر نیست در اینجا بیشتر مورد نظر قرار نگرفته است.

۱. به عنوان مثال در پژوهه گوگل اسکالار از پارادایم‌های گوناگون در کنار یکدیگر استفاده می‌شود (Emmert-Streib & Dehmer, 2022).

۲. هرچه سیستم با ناظری بیشتری طراحی شود، شفافیت افزایش پیدا خواهد کرد. با اینحال برای حل مسائل گوناگون نمی‌توان تنها از روش ناظری استفاده کرد و چنین سیستم‌هایی قادر به شناخت الگوهای کشف نشده برای ما نیستند؛ لذا انتخاب میزان ناظری همواره امری دلخواهانه نیست.

۳ Explainable Artificial Intelligence (XAI)

ماشین است. با توجه به روش‌های گوناگون یادگیری ماشین و ترکیب این روش‌ها برای مقاصد گوناگون، در هوش مصنوعی درون‌نما نیز از روش‌های مختلفی استفاده می‌شود^۱ (Holzinger et al., 2022). اما به صورت کلی، سیاست‌گذاری برای استفاده از روش‌های هوش مصنوعی درون‌نما می‌تواند شفافیت را برای فرد متخصص و غیرمتخصص افزایش دهد. تحقیقات گسترده‌ای که در این زمینه انجام شده نشان می‌دهد این روش می‌تواند تا حدود زیادی مسئله کدری استاندارد را برطرف کند (Longo et al., 2020; Zednik, 2021; Boelsen, 2022; Zednik, 2021). لذا در مجموع موارد دو بخش کدری کم‌عمق و کدری استاندارد می‌توان نتیجه گرفت که چالش شفافیت/کدری در سطح کدری کم‌عمق با راه‌کار سیاست‌گذاری و در سطح کدری استاندارد با راه‌کار سیاست‌گذاری و فنی قابل رفع باشد.

۳-۴. کدری عمیق

حالت سومی نیز وجود دارد که در آن نمی‌توان به سادگی به شفافیت دست یافت. برای مشخص شدن این موضوع باید به استفاده از تحلیل داده‌ها^۲ در هوش مصنوعی توجه کرد. اگر مجموعه‌ای از داده‌ها داشته باشیم، پیش از تحلیل نمی‌دانیم نتیجه تحلیل داده‌ها چه خواهد بود. ممکن است تصور شود داده‌ها حاوی اطلاعات نیستند. اما زمانی که با انبوهی از داده‌ها روبرو هستیم الگوها و ارتباط داده‌ها می‌تواند اطلاعات گوناگونی را از آن‌ها استخراج کند؛ البته مشخص نیست چه میزان اطلاعات در انبوه داده‌ها وجود دارد. در این شرایط می‌توان به الگوها و اطلاعاتی دست یافت که پیش‌تر بر اساس داده‌های اولیه از وجود آن‌ها ناآگاه بوده‌ایم. به چنین شرایطی که نمی‌دانیم و نمی‌توانیم بدانیم انبوه داده‌ها حاوی چه اطلاعاتی هستند، کدری عمیق گفته می‌شود (Muller, 2021: 20). با این صورت‌بندی از شکل سوم کدری، متوجه می‌شویم در ابعاد داده‌های انبوه و با استفاده از تحلیل داده‌ها در یادگیری ماشین مسئله حریم خصوصی و شفافیت همچنان حل نشده باقی

۱. از جمله مهم‌ترین روش‌های هوش مصنوعی درون‌نما می‌توان به روش‌های LIME, GraphLIME, Anchors, SHAP, ASV, XGNN, TCAV, DTD, LPR, Shapley Flow, Break-Down اشاره کرد (Holzinger et al., 2022).

۲. Data analytics

می‌ماند و به سختی ممکن است قابل برطرف کردن باشد. به عبارتی ما نمی‌دانیم: ۱- چه اطلاعاتی ممکن است به دست آید، لذا نمی‌توانیم اطمینان داشته باشیم که حریم خصوصی افرادی که از داده‌های آن‌ها استفاده می‌شود تا چه اندازه در خطر خواهد افتاد و ۲- الگوهایی جدید به دست خواهد آمد که پیش‌تر حتی از وجود آن‌ها مطلع نبوده‌ایم و با کدری عمیق روبرو هستیم.

۵. بحث و بررسی

همان طور که در ابتدا مطرح شد، اهداف اصلی این پژوهش بررسی ارتباط میان شفافیت و حریم خصوصی در هوش مصنوعی برای نقد رویکردهایی است که راهکار برطرف شدن چالش‌های اخلاقی را در طراحی و اصلاحات فنی می‌دانند. لذا در این بخش در ابتدا به ارتباط میان شفافیت و حریم خصوصی پرداخته می‌شود و سپس راهکار متمرکز بر طراحی به نقد گذاشته می‌شود.

۱-۵. ارتباط شفافیت و حریم خصوصی

بر اساس آنچه موردنبررسی قرار گرفت، در کدری کم‌عمق، ساختارهای قدرت؛ در کدری استاندارد، روش پردازش؛ و در کدری عمیق، محتوا و تنوع داده‌ها و توانایی ماشین در استخراج اطلاعات از آن‌ها، موضوع حفظ حریم خصوصی و کدری است.

مطابق مباحث بالا در کدری کم‌عمق، حفاظت از حریم خصوصی و رسیدن به شفافیت با اصلاح ساختارهای قدرت (سیاست‌گذاری) میسر بوده و به راه‌کارهای فنی نیاز نخواهیم داشت. در کدری استاندارد، نیاز به تصمیم‌گیری (به صورت سیاست‌گذاری برای استفاده از روش‌های درون‌نما) و اصلاحات فنی (به کارگیری روش‌های درون‌نما) خواهیم داشت. در کدری عمیق نمی‌دانیم داده‌ها حاوی چه اطلاعاتی هستند و چه الگوهایی از آن‌ها به دست خواهد آمد و لذا حفاظت از حریم خصوصی و دستیابی به شفافیت بسیار دشوارتر خواهد بود. از مجموع این موارد ممکن است به نظر بر سر میان افزایش شفافیت و حفاظت بیشتر از حریم خصوصی یک همگرایی وجود دارد چراکه در سیستم‌هایی که کدری بیشتر است، حفاظت از حریم خصوصی دشوارتر به نظر می‌رسد. این نتیجه‌گیری اولیه را پیش‌فرض رویکردهایی است که در این پژوهش قصد نقد به آن‌ها را داریم، اما آیا شفافیت حداکثری مطلوب‌ترین حالت خواهد بود؟ این موضوع، از دو جهت قبل تأمل است:

- ۱- باید اشاره کرد که افزایش حفاظت از داده‌ها در هوش مصنوعی تنها محدود به موضوع شفافیت نیست و نباید حفظ حریم خصوصی را ذیل شفافیت بررسی کرد (یا بر عکس). به عنوان مثال برخی از ابزارهای امنیتی این امکان را پدید می‌آورند که بتوان بدون شفافیت، محافظت بیشتری از داده‌ها انجام داد (Hagendorff, 2023). لذا بدون افزایش شفافیت نیز در برخی موارد می‌توان حفاظت از حریم خصوصی را بهبود بخشید و برای حفاظت از حریم خصوصی روش‌ها و راهکارهای دیگری نیز وجود دارند.
- ۲- افزایش شفافیت، خود به دور از مشکلات نیست. گاهی افزایش شفافیت می‌تواند به قیمت کاهش امنیت و به طبع آن در خطر افتادن حریم خصوصی تمام شود؛ به عنوان مثال احتمال هک شدن سیستم افزایش پیدا می‌کند (Whittlestone et al., 2019). به عبارتی دیگر، افزایش شفافیت گاهی می‌تواند مشکلات ثانویه ایجاد کند.
- از مجموع دو نکته یاد شده، به چهار نتیجه دست می‌یابیم:
- ۱- برخلاف تصور اولیه، یک همگرایی واقعی میان شفافیت و حفظ حریم خصوصی وجود ندارد و گاهی شفافیت منجر به کاهش حفاظت از حریم خصوصی می‌شود.
- ۲- راهکارهای دیگری برای حفظ حریم خصوصی خارج از مبحث شفافیت وجود دارد.
- ۳- شفافیت همواره مطلوب نیست.
- ۴- گاهی برطرف کردن برخی از چالش‌های اخلاقی خود می‌توانند منجر به تقویت چالش‌های اخلاقی دیگر در یادگیری ماشین شوند.
- تا به اینجا مشخص می‌شود که این پیش‌فرض که چالش‌های اخلاقی در هوش مصنوعی همگرا هستند، تصویر درستی نیست و می‌توان آن را با نمونه شفافیت و حریم خصوصی نقض کرد.

۵-۲. نقد به طراحی اخلاقی هوش مصنوعی

در ادامه با مطرح کردن سه چالش کمی‌سازی، محدودیت‌های فنی و موضوعات فرالاحدی به نقد رویکردهایی پرداخته می‌شود که راهکار حل مشکلات اخلاقی در هوش مصنوعی را به طراحی و اصلاحات فنی محدود می‌سازند. قابل توجه است که از منظر فلسفی، این رویکردها عموماً بر واقع‌گرایی اخلاقی تأکید دارند (Häggström, 2021) و اتخاذ چنین موضوعی خود به دور از مخالفت نخواهد بود.

مطابق با اولین چالش، به کارگیری قواعد و کدهای اخلاقی در هوش مصنوعی به زبان

ریاضیات انجام می‌شود؛ به عبارتی موضوعات اخلاق هوش مصنوعی را به معیارهای کمی برای رسیدن به اهداف و شرایط مشخص تبدیل می‌کنیم (Hagendorff, 2022). برای روشن شدن این چالش به موضوع رضایت آگاهانه فرد رجوع می‌کنیم. یک پرسش این است که آیا رضایت آگاهانه را می‌توان با معیار کمی تضمین کرد؟ برای رضایت آگاهانه، نیازمند آگاهی از روند پیچیده در ماشین هستیم. اگر آگاهی را به دانستن هدف اصلی ماشین از داده‌ها تقلیل دهیم، این پاسخ چندان رضایت‌بخش نخواهد بود؛ چراکه در دل خود تو ضیح حریم خصوصی را بی‌معنا می‌کند. به عبارتی همان‌طور که در تعریف هوش مصنوعی ذکر شد، هوش مصنوعی نوعی سیستم محاسباتی است که برای رسیدن به هدف یا اهداف موردنظر رفتارهای هوشمند اتخاذ می‌کند. درنتیجه می‌توان گفت هر هوش مصنوعی رضایت آگاهانه را تضمین می‌کند چراکه برای هدفی مشخص طراحی شده و لذا با مسئله اخلاقی روبرو نیستیم.

اگر مقصود از رضایت آگاهانه اطلاع از روند رسیدن به نتیجه باشد، آن‌گاه نیازمند شفافیت خواهیم بود. در اینجا دو نکته قابل تأمل است. اول، مطابق بررسی‌های بالا دانستیم که شفافیت خود چالش‌هایی به همراه دارد (مثلاً می‌تواند گاهی حریم خصوصی را در خطر بیندازد)؛ و دوم برای کدری عمیق گاهی رسیدن به شفافیت امکان‌پذیر نیست. حال برای مواردی که امکان دست‌یابی به شفافیت وجود دارد، مثلاً در شیوه درون‌نما ماشین به گونه‌ای طراحی می‌شود که روند رسیدن به نتیجه را ساده‌سازی می‌کند. در برخی موضوعات، ساده‌سازی برای انتخاب آگاهانه می‌تواند کاربردی باشد. گاهی تنها نیاز است روند رسیدن به نتیجه به صورت یک دیاگرام ارائه شود، اما در مسائل پیچیده، ساده‌سازی خود تبدیل به چالش می‌شود. در چنین شرایطی با این پرسش مواجه می‌شویم که چه میزان ساده‌سازی لازم است تا یک فرد غیرمتخصص بتواند اطمینان حاصل کند که آگاهانه تصمیم‌گیری کرده است؟ ساده‌سازی ماشین را در قالب یک مدل می‌توان بررسی کرد. در کیک مدل پیشرفت‌هه می‌تواند برای یک متخصص هم چالش‌برانگیز باشد. به خصوص آنکه ممکن است ماشین‌الگوها و مدل‌های جدیدی از داده‌ها بیابد که پیش‌تر با آن‌ها آشنا نیای نداشته‌ایم. این موضوع زمانی دشوارتر می‌شود که می‌دانیم ماشین همواره در حال یادگیری است و مدل در طول زمان تغییر می‌کند. در این شرایط با یک پرسش معرفت‌شناسی قدیمی در فلسفه علم روبرو می‌شویم. اینکه کدام یک از مدل‌های ساده یا مدل‌های پیچیده فهم درست‌تری به دست دهنده هنوز در میان فیلسوفان

علم مورد بحث بوده و به اتفاق نظری دست نیافته ایم (به عنوان مثال رج Bokulich, 2008; Streven, 2008; Kuorikoski & Ylikoski, 2015) و در اینجا نیز این پرسش همچنان پا بر جاست. همچنین قابل توجه است که برای موضوعاتی که نیازمند اطلاع کیفی هستیم، معیارهای کمی برای سنجش آگاهی از روند رسیدن ماشین به نتیجه چندان رضایت‌بخش نخواهد بود.

چالش دوم این است که به کارگیری کدهای اخلاقی در هوش مصنوعی گاهی با محدودیت‌های فنی روبرو است. اگرچه فیلسوفان و متخصصین اخلاق و حقوق، ممکن است بتوانند در رسیدن به تحلیل‌های مفهومی و تفاسیر اصطلاحی موفق عمل کنند، اما دست آخر آن‌ها کدهای اخلاقی را پیاده‌سازی نمی‌کنند و یک نظارت همیشگی بر تصمیمات سیستم ندارند. در عمل این طراحان هوش مصنوعی هستند که می‌توانند با درکی که از این کدها به دست آورده‌اند و با توجه به ظرفیت‌های فنی، کدها را در ماشین پیاده‌سازی کنند. از پس این محدودیت‌های فنی، گاهی مشکلات متعددی بروز پیدا می‌کند. به عنوان مثال زمانی که از هوش مصنوعی درون‌نما استفاده می‌شود و صد قابل فهم کردن تصمیم ماشین برای انسان است. با این حال اطلاع از این که یک خروجی سیستم هوش مصنوعی در چه فرآیندی به دست آمده، به معنای موجه دانستن آن خروجی نیست. به سخنی دیگر، اینکه سیستم بر چه اساس تصمیم‌گیری کرده است (درون‌نما)، توجیه کننده آن تصمیم نیست (*ibid*). حال حتی اگر موجه بودن برای تمامی اشکال کدری نیز میسر شود، کما کان پیاده‌سازی کدهای اخلاقی بر اساس ظرفیت‌های فنی پاسخ رضایت‌بخشی نخواهد بود. می‌توان این ایراد را با یک پرسش بیان کرد: اگر ظرفیت‌های فنی امکان پیاده‌سازی برخی از کدهای اخلاقی را نداشته باشد، مجاز هستیم از آن کدهای اخلاقی چشم‌پوشی کنیم و یا شایسته است از روش‌های دیگر نیز بهره ببریم؟

چالش سوم از محدودیت‌های طراحی اخلاقی هوش مصنوعی است. سه شکل کلی از طراحی اخلاقی هوش مصنوعی وجود دارد. در شکل اول هوش مصنوعی به گونه‌ای طراحی می‌شود که تصمیمات اخلاقی، تحت کنترل و توسط افراد متخصص گرفته می‌شود. این نوع طراحی زمانی قابل استفاده است که ما شنی عملکردی شفاف، روند آن ساده است، تصمیم‌گیری محدود بوده و عامل انسانی می‌تواند نظارت و تصمیم‌گیری به موقع داشته باشد. در شکل دوم، ماشین ظرفیت ارزیابی و پاسخگویی به چالش‌های

اخلاقی در موضوع مشخص را دارد. به عنوان مثال تمامی شرایط از قبل در طراحی پیش‌بینی شده و ما شین بر اساس عملکرد، پاسخ اخلاقی مشخصی را یافته و طبق آن عمل می‌کند. در شکل سوم، ما شین یک عامل اخلاقی^۱ دانسته می‌شود. در این حالت ما شین به صورت خودکار خروجی‌ها و تصمیمات اخلاقی را بر عهده گرفته و یادگیری او شامل یادگیری اخلاق نیز می‌شود (Wallach & Allen, 2009). پرواصل است که دو حالت اول را نمی‌توان برای کلان داده‌ها که با تصمیم‌گیری‌های فراوان و روندهای پیچیده و شاید ناشناخته رو برو هستیم به کار برد.

در شکل سوم طراحی ماشین دو رویکرد عمدۀ وجود دارد. در رویکرد نخست، قضاوت‌های توصیفی^۲ اخلاقی وابسته به شرایط گوناگون به عنوان داده‌های آموزشی ماشین به کار گرفته می‌شوند. در رویکرد دوم قواعد تجویزی^۳ اخلاقی، داده‌های آموزشی و خروجی‌های ماشین را هدایت می‌کنند؛ به این صورت که اگر قضاوت‌های انسانی و داده‌های آموزشی، هنجارهای اخلاقی را نقض کنند، ماشین آن‌ها را بر اساس قواعد تجویزی که در ابتدا دریافت کرده، بازنویسی و اصلاح می‌کند. این دو رویکرد معمولاً در کار هم به کار می‌روند. در این شکل ماشین از قضاوت‌های فردی به عنوان داده‌های آموزشی استفاده می‌کند و بخشی از یادگیری ماشین، یادگیری یافتنِ الگوهای اخلاقی است و سپس با قواعد تجویزی، داده‌ها و قضاوت‌هایی که هنجارهای اخلاقی را نقض می‌کنند اصلاح می‌شوند. اگرچه شکل سوم طراحی اخلاقی ماشین برای برخی از مسائل اخلاقی، عملکرد خوبی از خود نشان داده، اما همچنان برخی مشکلات وجود دارد.^۴. به عنوان مثال در موضوعات فرا اخلاقی که اتفاق نظر وجود ندارد، طراحی با مشکل رو برو است. همچنین قابل ذکر است که این شکل سوم رو به سوی گذشته دارد؛ به عبارتی هوش مصنوعی مشکلات اخلاقی که در آینده با آن‌ها رو برو می‌شویم را باید با توجه به آموزش‌ها و کدهای اخلاقی که بر اساس شرایط گذشته ارائه شده‌اند، موردنرسی قرار

۱. Moral Agent

۲. Descriptive

۳. Prescriptive

۴. به عنوان موفق‌ترین نمونه می‌توان به Delphi اشاره کرد که البته این هوش مصنوعی نیز با برخی چالش‌های اخلاقی و فرآخلاقی رو برو است (Hagendorff & Danks, 2022).

دهد. حال آنکه عامل اخلاقی نمی‌تواند تنها با الگوهای گذشته رجوع کرده و گاهی نیاز به اتخاذ رویکرد هنجاری داریم (Hagendorff & Danks, 2022). لذا راهکار طراحی در موضوعاتی مانند حریم خصوصی با نگاه رو به گذشته و رویکرد توصیفی در اخلاق مواجه خواهد بود.

پیش‌تر اشاره شد که در کلان داده‌ها ممکن است الگوهای ناشناخته به دست آید؛ حال اگر در برابر الگوهای ناشناخته تنها به طراحی بستنده کرده و پیرو آن به الگوهای قدیمی رجوع کنیم، نمی‌توان تصمیم‌گیری‌های اخلاقی در الگوهای جدید را توجیه کرد. در این شرایط نمی‌دانیم تأثیر این الگوها چیست، چه شرایطی به وجود می‌آورند و آیا با رجوع به شرایط گذشته استفاده از این تصمیم‌گیری‌ها در شرایط جدید نیز توجیه پذیر خواهد بود یا خیر.

از مجموع مواردی که در بالا مطرح شد، می‌توان نتیجه گرفت که اگر تنها به طراحی هوش مصنوعی تکیه کنیم، محدودیت‌های گوناگونی وجود خواهد داشت که منجر می‌شود دست ما در برابر چالش‌های اخلاقی در برخی موقعیت‌ها خالی باشد. پیشرفت‌های شگرفی در حوزه هوش مصنوعی رخ داده، اما اگر چشم بر روی محدودیت‌های فعلی بیندیم و توانایی‌های کنونی را بیش از آنچه هست بدانیم، دچار اشتباكات محاسباتی خواهیم شد. البته دو نکته در راستای انتقاداتی که مطرح شده وجود دارد. اول، اگرچه چالش‌های مختلفی در طراحی پیش روی ما قرار دارد، اما به این معنا نیست که مقصود این است که از ظرفیت هوش مصنوعی بهره برده نشود؛ دوم آنکه برای فائق آمدن بر چالش‌های موجود می‌توان از روش‌های دیگر در کنار تلاش برای غلبه بر محدودیت‌های طراحی و فنی استفاده کرد. قانون‌گذاری، پیشرفت در علوم داده‌ها و روش‌های مختلف دیگر می‌تواند کمک کند تا بخشی از محدودیت‌های موجود را برطرف کرد!

۱. تأکید ما بر این است که با توجه به محدودیت‌های موجود، بایسته است که از روش‌های مختلف در کنار هم و نه به عنوان جایگزین بهره برد. در بسیاری موارد نیز این رویکرد مورد توجه قرار گرفته است. به عنوان نمونه می‌توان به قانون‌گذاری GDPR اشاره کرد. البته این راه کارها نیز خالی از ایراد نبوده و به همین دلیل پیشنهاد استفاده از چندین راه کار شده است. به عنوان مثال سیلویا لو نشان می‌دهد که افشاگری از الگوریتم از طریق گزارش‌های پایداری و حفاظت از افشاگران در برابر شرکت‌هایی که هوش مصنوعی را به کار می‌گیرند، می‌تواند جایگزین بهتری از قوانین سخت‌گیرانه‌ای مانند GDPR باشد که در برابر حفاظت از داده‌ها چندان موفق نبوده‌اند (Lu, 2022: 2087-2088).

نتیجه‌گیری

با توجه به اهداف مطرح شده، یافته‌های این پژوهش به دو بخش تقسیم‌بندی می‌شود. در بخش اول، نتایج نشان می‌دهد که در مباحث اخلاق هوش مصنوعی، میان شفافیت/کدری و حریم خصوصی یک همگرایی وجود ندارد. به عبارتی دیگر، افزایش شفافیت تضمین کننده حفاظت از حریم خصوصی نیست. قابل توجه است، در صورتی که این دو مبحث به صورت همگرا موردنظر قرار گیرند، ثمره آن می‌تواند در خطر افتادن حریم خصوصی باشد. گاهی ممکن است شفافیت و حفاظت از حریم خصوصی در یک هوش مصنوعی با یکدیگر بهبود یابند اما این موضوع یک قاعده کلی نبوده و نباید آن را به معنای تقویت یکی توسط دیگری دانست. همچنین مشخص شد برای حفاظت از حریم خصوصی در هوش مصنوعی روش‌های متفاوتی وجود دارد و همواره نیازمند شفافیت نخواهیم بود. این نتایج به صورت ضمنی مؤید این است که چرا مباحث اخلاقی هوش مصنوعی را به عنوان مباحث جداگانه و غیرهمگرا بررسی کنیم. این عدم همگرایی نشان می‌دهد ما با مباحث مهم و نه یک مبحث اخلاقی و زیرمجموعه‌های آن مواجه هستیم. در بخش دوم نتایج پژوهش نشان می‌دهد برای پاسخ به چالش‌های اخلاقی، اگرچه در بسیاری موارد راه کارها و اصلاحات فنی و طراحی نتیجه‌بخش است، اما در برخی شرایط با محدودیت‌هایی مواجه است و به تنهایی برای همه شرایط راهگشا نخواهد بود. همان‌طور که راه کارهای فلسفی و اخلاقی که نگاهی به ساختارهای مختلف هوش مصنوعی ندارند، می‌توانند به تحلیل‌های کلی که در بسیاری موارد ارتباطی با ساختارهای هوش مصنوعی ندارد منتج شود؛ اگر راه کارهای فنی را نیز بدون توجه به شرایط مختلف به عنوان راه کارهای کلی در نظر بگیریم باز به شیوه‌ای دیگر دچار اشتباہ خواهیم شد. در چنین شرایطی نیاز است از سایر روش‌ها مانند قانون‌گذاری، پیشرفت در علوم گوناگون در کنار طراحی اخلاقی استفاده شود تا بتوان بخشی از محدودیت‌های موجود را برطرف ساخت.

تعارض منافع

تعارض منافع ندارد.

ORCID

Mohammad Ali Ashouri
Kisomi



<https://orcid.org/0000-0001-5663-1993>

منابع

- Barhamgi, M. Bertino, E. (2022). Special Issue on Data Transparency—Uses Cases and Applications. *ACM Journal of Data and Information Quality (JDIQ)*, 14(2), 1-3. <https://doi.org/10.1145/3494455>
- Bhatnagar, R. (2019). Unleashing Machine Learning onto Big Data: Issues, Challenges and Trends. In Aboul Ella Hassanien (Eds.), *Machine learning paradigms: Theory and application* (pp. 271-286). Cham: Springer. https://doi.org/10.1007/978-3-030-02357-7_13
- Blaauw, M. (2013). The Epistemic account of privacy. *Episteme*, 10(2), 167-177. doi:10.1017/epi.2013.12
- Bokulich, A. (2008). Reexamining the Quantum-Classical Relation, Cambridge: Cambridge University Press.
- DeCew, J. (2018). Privacy. Edward N. Zalta (Eds.). *The Stanford Encyclopedia of Philosophy*. Retrieved April 8, 2023, from <https://plato.stanford.edu/archives/spr2018/entries/privacy>
- Descartes, R. (1955). The philosophical works of Descartes, Voume 1 (E.S, Haldane & G.R.T, Ross Trans.). New York: Dover Publications.
- Danaher, J. (2016). The Threat of Algocracy: Reality, Resistance and Accommodation. *Philosophy & Technology*, 29(3): 245–268. doi:10.1007/s13347-015-0211-1
- Diakopoulos, N. (2015). Algorithmic Accountability: Journalistic Investigation of Computational Power Structures. *Digital Journalism*, 3(3): 398–415. doi:10.1080/21670811.2014.976411
- El Naqa, I. Murphy, M. (2015). What is machine learning? In El Naqa, I. Li, R & Murphy, J (Eds.), *Machine Learning in Radiation Oncology*. Springer International Publishing.
- Emmert-Streib, F. Dehmer, M. D. (2022). Taxonomy of machine learning paradigms: A data-centric perspective. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 12(5), e1470. <https://doi.org/10.1002/widm.1470>
- Falsinski, M. (2016). *Introduction to Artificial Intelligence*. Springer.
- Franzoni, V. (2023). From Black Box to Glass Box: Advancing Transparency in Artificial Intelligence Systems for Ethical and Trustworthy AI. In: Gervasi, O., et al. *Computational Science and Its Applications – ICCSA 2023 Workshops*. ICCSA 2023. Lecture Notes in Computer Science, vol 14107. Springer, Cham. https://doi.org/10.1007/978-3-031-37114-1_9

- Hagendorff, T. (2023). Information Control and Trust in the Context of Digital Technologies. In Varieties of Cooperation: Mutually Making the Conditions of Mutual Making (pp. 189-201). Wiesbaden: Springer Fachmedien Wiesbaden. https://doi.org/10.1007/978-3-658-39037-2_9
- Hagendorff, T. (2022). Blind spots in AI ethics. *AI and Ethics*, 2(4), 851-867. <https://doi.org/10.1007/s43681-021-00122-8>
- Hagendorff, T. Danks, David. (2022). Ethical and methodological challenges in building morally informed AI systems. *AI Ethics*, 1-14. <https://doi.org/10.1007/s43681-022-00188-y>
- Hagendorff, T. Wezel, K. (2020). 15 challenges for AI: or what AI (currently) can't do. *AI & Society*, 35, 355-365. <https://doi.org/10.1007/s00146-019-00886-y>
- Häggström, O. (2021). AI, orthogonality and the Muller-Cannon instrumental vs general intelligence distinction. arXiv e-prints, arXiv-2109. <https://doi.org/10.48550/arXiv.2109.07911>
- Holzinger, A. Sarnati, A. Molnar, C. Biecek, P. Samek, W. (2022). Explainable AiMethods – A Brief Overview. In *xxAI-Beyond Explainable AI: International Workshop, Held in Conjunction with ECML 2020, July 2018, Vienna, Austria, Revised and Extended Papers* (13-38). Cham: Springer International Publishing. https://doi.org/10.1007/978-3-031-04083-2_2
- Jobin, A. Ienca, M. Vayena, E. (2019). The global landscape of AI ethics guidelines. *Nature Machine Intelligence*, 1(9), 389-399. <https://doi.org/10.1038/s42256-019-0088-2>
- Jung, A. (2022). Machine Learning, The Basics. Springer Singapore.
- Kalita, J. (2022). Machine Learning: Theory and Practice. Boca Raton: CRC Press.
- Kuorikoski, J. Ylikoski P. (2015). External Representations and Scientific Understanding. *Synthese*, 192(12), pp. 3817–37.
- Lee, J. Kang, H. Lee, Y. Choi, W. Eom, J. Deryabin, M. Lee, E. Lee, J. Yoo, D. Kim, Y. No, Jong-Seon. (2022). Privacy-preserving machine learning with fully homomorphic encryption for deep neural network. *IEEE Access*, 10, 30039-30054. doi: 10.1109/ACCESS.2022.3159694.
- Liu, Z. Guo, J. Lam, K. Zhao, J. (2022). Effective dropout-resilient aggregation for privacy-preserving machine learning. *IEEE Transactions on information forensics and security*. 18, 1839-1854. doi: 10.1109/TIFS.2022.3163592.
- Longo, L. Goebel, R. Lecue, F. Kieseberg, P. Holzinger, A. (2022). Explainable artificial intelligence: Concepts, Applications, research challenges and visions. In *Machine learning and Knowledge Extraction: 4th IFIP TC 5, TC 12, WG 8.4, WG 8.9, WG 12.9 International Cross-Domain Conference, CD-Make 2020, Dublin*,

- Ireland, August 25-28, 2020, Proceeding (pp. 1-16). Cham: Springer International Publishing. https://doi.org/10.1007/978-3-030-57321-8_1
- Lu, S. (2022). Data privacy, human rights, and algorithmic opacity. *Cal. L. Rev.*, 110, 2087-2147.
- Matheson, D. (2008). A Distributive Reductionism About the Right to Privacy. *The Monist*, 91(1), 108-129.
<https://doi.org/10.5840/monist200891115>
- Morozov, E. (2013). To save everything, click here: The folly of technological solutionism. New York: PublicAffairs.
- Muller, V. (2009). Would you mind being watched by machines? Privacy concerns in data mining. *AI & society*, 23(4), 529-544.
<https://doi.org/10.1007/s00146-007-0177-3>
- Muller, V. (2012). Introduction: Philosophy and Theory of Artificial Intelligence. *Minds, & Machines*, 22(2), 67-69.
<https://doi.org/10.1007/s11023-012-9278-y>
- Muller, V. (2021). Deep opacity undermines data protection and explainable artificial intelligence. In Overcoming opacity in machine learning.
- Muller, V. (2021a). Ethics of Artificial Intelligence and Robotics. The Stanford Encyclopedia of Philosophy. Retrieved April 7, 2023, from <https://plato.stanford.edu/entries/ethics-ai/>
- Muller, V. Bostrom, N. (2016). Future progress in artificial intelligence: A survey of expert opinion. *Fundamental issues of artificial intelligence*, 555-572. https://doi.org/10.1007/978-3-319-26485-1_33
- Nissenbaum, H. (2004). Privacy as contextual integrity. *Washington Law Review Association*, 79(2-1), 119-157.
- Rolf, B. Jackson, I. Müller, M. Lang, S. Reggelin, T. Ivanov, D. (2022). "A review on reinforcement learning algorithms and applications in supply chain management". *International Journal of Production Research*, 1-29.
- Russel, S. Norvig, P. (2020). Artificial intelligence: A Modern Approach, Fourth Edition. London: Pearson.
- Sengan, S. Khalaf, O. I. Sharma, D. K. Hamad, A. A. (2022). Secure and Privacy-Based IDS for healthcare systems on E-medical data using machine learning approach. *International Journal of Reliable and Quality E-healthcare (IJRQEH)*, 11(3), 1-11. Doi: 10.4018/IJRQEH.289175
- Strevens, M. (2008). Depth: An Account of Scientific Explanation. Cambridge: Harvard University Press.
- Thomas, W. (2015). Algorithms: From Al-Khwarizmi to Turing and Beyond. In G. Sommaruga & T. Strahm (Eds.), *Turing's revolution: The impact of his ideas about computability*, 29-42.
- Turing, A. (1950). Can machine think. *Mind*, 59(236), 433-460.

- Van den Hoven, J. Blaauw, M. Pietres, W. Warnier, Martjn. (2020). *Privacy and Information Technology*. The Stanford Encyclopedia of Philosophy. Retrieved April 6, 2023, from <https://plato.stanford.edu/entries/it-privacy>
- Wallach, W. Allen, C. (2009). Moral Machines: Teaching Robots Right from Wrong. New York: Oxford University Press.
- White, A. (2014). Digital media and society: transforming economics, politics and social practices. UK: Springer.
- Whittlestone, J. Nyrup, R. Alexandrova, A. Cave, S. (2019, January). The role and limits of principles in AI ethics: towards a focus on tensions. In *Proceedings of the 2019 AAAI/ACM Conference on AI, Ethics, and Society* (pp. 195-200).
- Worden, K., Tsialiamanis, G., Cross, E. J. Rogers, T. J. (2023). Artificial neural networks. In Machine Learning in Modeling and Simulation: Methods and Applications (pp. 85-119). Cham: Springer International Publishing.
- Zednik, C. (2021). Solving the black box problem: A normative framework for explainable artificial intelligence. *Philosophy & technology*, 34(2), 265-288. <https://doi.org/10.1007/s13347-019-00382-7>
- Zednik, C. Boelsen, H. (2022). Scientific exploration and explainable artificial intelligence. *Minds and Machines*, 32(1). 219-239. <https://doi.org/10.1007/s11023-021-09583-6>

استناد به این مقاله: عاوری کیسمی، محمدعلی، همگرایی حریم خصوصی و شفافیت، محدودیت‌های طراحی هوش مصنوعی، حکمت و فاسنده، ۲۰ (۷۸)، ۴۵-۷۳.

DIO: 10.22054/wph.2024.75680.2183



Hekmat va Falsafeh is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.