A Review and Formulation of Ethical Guidelines for the Development and Deployment of Artificial Intelligence Systems

Alireza Seghatoleslami*
PhD in Philosophy of Science; Assistant Professor; Information and Society Research Department; Iranian Research Institute for Information Science and Technology (IranDoc); Tehran, Iran;
Email: Seghatoleslami@irandoc.ac.ir

Iranian Journal of Information Processing and Management

Received: 19, Jul. 2025 **Accepted: 25, Aug. 2025**

Iranian Research Institute for Information Science and Technology (IranDoc)
ISSN 2251-8223
eISSN 2251-8231
Indexed by SCOPUS, ISC, & LISTA
Vol. 41 | No. 2 | pp. 419-440
Winter 2026
https://doi.org/10.22034/jipm.2025.2066388.2053

Abstract: The ethics of artificial intelligence is a relatively emerging field within the scope of applied ethics, which is influenced by the transformations driven by the development and deployment of AI systems and examines the ethical and social implications and issues associated with them. Although some of these consequences and ethical issues have been somewhat predictable and have enabled ethical analyses and investigations, it appears that as AI systems increasingly penetrate all dimensions and aspects of individual and social life, certain ambiguous and complex ethical challenges are also arising. Therefore, in the field of AI ethics studies, there does not actually exist a set of issues that are well-established or enjoy an acceptable level of comprehensiveness. Nonetheless, numerous efforts have been made by national and international organizations to collect and draft principles and ethical guidelines for AI in the past decade. Each AI ethics document generally consists of two parts: ethical principles and ethical guidelines. The ethical principles in these documents form the basis for formulating the ethical guidelines. The goal of this article is to introduce principles and develop ethical guidelines for AI ethics through the study of seven national and international documents. On this basis, the five integrative ethical principles of Floridi and Cowls were used as the foundation for compiling and examining AI ethical guidelines. These guidelines were reviewed in three stages. In the first stage, ethical guidelines were extracted from the aforementioned documents and listed within the framework of the five ethical principles. In the second stage, the collected guidelines were harmonized and refined. In the third stage, to evaluate the validity of the findings and the research outcome, the refined ethical guidelines were critiqued and reviewed by a focus group of experts under the five ethical principles to ensure the credibility of the selected ethical guidelines by achieving a relative consensus among the experts.

Keywords: AI Ethics, Ethical Principles, AI Ethics Document, Ethical Guidelines, Artificial Intelligence

* Corresponding Author

بررسی و تدوین رهنمودهایی اخلاقی برای توسعه و استقرار سیستم‌های هوش مصنوعی

علیرضا ثقه‌الاسلامی

دکتری فلسفهٔ علم؛ استادیار؛ پژوهشگاه علوم و فناوری اطلاعات (ایرانداک)؛ تهران، ایران؛
پدیدآور رابط Seghatoleslami@irandoc.ac.ir

پژوهش‌نامهٔ پردازش و مدیریت اطلاعات

دریافت: ۱۴۰۴/۰۴/۲۸ **پذیرش:** ۱۴۰۴/۰۶/۰۳ مقاله برای اصلاح به مدت ۶ روز نزد پدیدآوران بوده است.

نشریهٔ علمی | رتبهٔ بین‌المللی
پژوهشگاه علوم و فناوری اطلاعات ایران (ایرانداک)
شاپا (چاپی) ۸۲۲۳-۲۲۵۱
شاپا (الکترونیکی) ۸۲۳۱-۲۲۵۱
نمایه در LISTA، ISC، و SCOPUS
jipm.irandoc.ac.ir
دورهٔ ۴۱ | شمارهٔ ۲ | ص‌ص ۴۱۹-۴۴۰
زمستان ۱۴۰۴
https://doi.org/10.22034/jipm.2025.2066388.2053

چکیده: اخلاق هوش مصنوعی حوزه مطالعاتی نسبتاً نوظهوری در گستره اخلاق کاربردی است که متأثر از تحولات ناشی از توسعه و استقرار سیستم‌های هوش مصنوعی به بررسی پیامدها و مسائل اخلاقی و اجتماعی مرتبط با آن می‌پردازد. اگرچه برخی از این پیامدها و مسائل اخلاقی تا حدی قابل پیش‌بینی بوده و امکان تحلیل‌ها و بررسی‌های اخلاقی را فراهم آورده است، اما به نظر می‌رسد با رشد و نفوذ روزافزون سیستم‌های هوش مصنوعی در تمامی ابعاد و شئون زندگی اجتماعی و فردی انسان‌ها، چالش‌های اخلاقی مبهم و پیچیده‌ای نیز در حال بروز است. این است که در حوزه مطالعاتی اخلاق هوش مصنوعی، مجموعه مسائلی که به‌خوبی تثبیت شده یا از جامعیت قابل قبولی برخوردار باشد، در واقع وجود ندارد. البته، تلاش‌های متعددی توسط سازمان‌های ملی و بین‌المللی در حوزه گردآوری و تدوین اصول و رهنمودهای اخلاق هوش مصنوعی در یک دهه اخیر انجام شده است. هر سند اخلاق هوش مصنوعی به‌طور معمول، شامل دو بخش اصول اخلاقی و رهنمودهای اخلاقی است. در این سندها اصول اخلاقی، مبنای گردآوری و صورت‌بندی رهنمودهای اخلاقی است. هدف این مقاله معرفی اصول و تدوین رهنمودهای اخلاقی هوش مصنوعی با مطالعه هفت سند ملی و بین‌المللی است. بر این اساس، پنج اصل اخلاقی یکپارچه «فلوریدی و کولز» مبنای گردآوری و بررسی رهنمودهای اخلاقی هوش مصنوعی قرار گرفت. این رهنمودها در سه مرحله بررسی شد. در مرحله اول، رهنمودهای اخلاقی از اسناد مذکور استخراج و در چارچوب پنج اصل اخلاقی فهرست شدند. در مرحله دوم، رهنمودهای گردآوری‌شده، یکدست‌سازی و پالایش گردیدند. در مرحله سوم، برای ارزیابی روایی یافته‌ها و دستاورد پژوهش، رهنمودهای اخلاقی پالایش‌شده ذیل اصول اخلاقی پنج‌گانه، توسط گروهی کانونی از متخصصان، نقد و بررسی شد تا فرایند اعتباربخشی به رهنمودهای اخلاقی برگزیده با دستیابی

به اِجماعی نسبی میان متخصصان انجام یابد.

کلیدواژه‌ها: اخلاق هوش مصنوعی، اصول اخلاقی، سند اخلاق هوش مصنوعی، رهنمودهای اخلاقی، هوش مصنوعی

۱. مقدمه

در دهه‌های آخر قرن بیستم، اولین ایده‌های طراحی و ساخت ماشین‌هایی با قابلیت شبیه‌سازی فرایندهای فعالیت‌های ذهنی انسان مطرح شد. این ماشین‌ها و ابزارها در واقع، سیستم‌های رایانشی هوشمندی هستند که با پردازش و مدل‌سازی کلان‌داده‌ها می‌توانند یاد بگیرند و استنتاج کنند، و در نهایت تصمیم‌گیری و عمل نمایند (بهاری ۱۳۹۸، ۱۶). با گسترش این سیستم‌های خودگردانِ هوشمند و پیشرفت علم رباتیک در چند دهه اخیر و ارتقای روزافزون حساسیت‌های اخلاقی نسبت به نفوذ هنجاری و تثبیت جایگاه سیستم‌های هوشمند در زندگی روزمره انسان‌ها، تحلیل‌گران و سیاست‌گذاران در ارتباط با چنین مباحثی، پیوسته درگیر سناریوهای افراطی میان دو-قطبی‌های خوش‌بینانه و بدبینانه نسبت به توسعه هوش مصنوعی و پیامدهای اخلاقی آن بوده‌اند. شاید بدین خاطر است که دهه‌های ۱۹۸۰ و ۱۹۹۰ به‌عنوان «زمستان هوش مصنوعی» شناخته می‌شود؛ دورانی که هوش مصنوعی به‌منزله تهدید و چالش دوران معاصر مطرح گردید. برخی از اندیشمندان گسترش و استفاده از سیستم‌های خودگردان هوشمند و فراگیر شدنِ استفاده از آن‌ها را تهدیدی مهلک برای جامعه بشری پیش‌بینی کردند.

با وجود این سناریوهای افراطی، انسان‌ها در سال‌های اخیر منافع بسیاری را در ابعاد نظری و عملی در توسعه و استقرار سیستم‌های هوش مصنوعی مشاهده کرده‌اند. از این‌رو، امروزه با فراگیر شدن استفاده از سیستم‌های خودمختار هوشمند و با توجه به دستاوردهای آن‌ها در حوزه‌های پزشکی، مهندسی، اقتصادی، حقوقی و موارد دیگر، بحث‌ها و بررسی‌های روان‌شناختی، جامعه‌شناختی، فلسفی، اخلاقی و حقوقیِ روش‌مندی حول این دستاوردها شکل گرفته است که نحوه مواجههٔ تحلیل‌گران و سیاست‌گذاران در توسعه هوش مصنوعی را تحت تأثیر قرار می‌دهد. هوش مصنوعی می‌تواند نقش مهمی در تسهیل، تدقیق و تسریع بسیاری از فعالیت‌ها در جوامع بشری ایفا کند؛ چرا که برای ارتقای کیفی فعالیت‌ها، به روش‌های هوشمندانه‌تری برای پردازش مقادیر بسیار زیاد داده، پایداری و کارآمدی نیاز داریم. با وجود این توصیف‌ها، هوش مصنوعی را باید

به‌عنوان یک فناوری متعارف تلقی کرد، نه به‌عنوان یک معجزه و نه به‌عنوان طاعون، بلکه به‌عنوان یکی از راه‌حل‌های بسیاری که نبوغ بشر توانسته است آن را ابداع کند. به همین دلیل است که مباحث اخلاقی مرتبط با توسعه هوش مصنوعی، همچون بسیاری از ملاحظات اخلاقی مرتبط با توسعه حوزه‌های متنوع علم و فناوری، پرسشی کاملاً انسانی بوده و از جایگاهی حیاتی برخوردار است (Floridi 2023, 2-3).

اخلاق هوش مصنوعی، حوزه مطالعاتی نسبتاً نوظهوری در گستره اخلاق کاربردی است که متأثر از تحولات ناشی از توسعه و استقرار سیستم‌های هوش مصنوعی به بررسی پیامدها و مسائل اخلاقی و اجتماعی مرتبط با آن می‌پردازد. اگرچه برخی از این پیامدها و مسائل اخلاقی تا حدی قابل پیش‌بینی بوده و امکان تحلیل‌ها و بررسی‌های اخلاقی را فراهم کرده است، اما به نظر می‌رسد با رشد و نفوذ روزافزون سیستم‌های هوش مصنوعی در تمامی ابعاد و شئون زندگی اجتماعی و فردی انسان‌ها، چالش‌های اخلاقی مبهم و پیچیده‌ای نیز در حال بروز است. این است که می‌توان گفت در حوزه مطالعاتی اخلاق هوش مصنوعی، مجموعه مسائلی که به‌خوبی تثبیت‌شده یا از جامعیت قابل قبولی برخوردار باشد، در واقع وجود ندارد (Müller 2020).

با گسترش و استفاده فراگیر از کامپیوتر و افزایش قدرت محاسباتی در ماشین‌های محاسبه‌گر، دهه ۱۹۵۰ تا ۱۹۷۰ را می‌توان سرآغاز «عصر طلایی هوش مصنوعی» تلقی کرد. از این‌رو، دولت‌ها و شرکت‌های خصوصی بزرگ سرمایه‌گذاری‌های کلانی برای تحقیقات نظری و کاربردی در زمینه هوش مصنوعی صرف کردند. اما با گذر زمان، برخی دانشمندان استفاده از سیستم‌های خودگردانِ هوشمند و فراگیری استفاده از آن را تهدیدی جدی برای جامعه بشریت معرفی نمودند. در ابتدا، خطرهایی نظیر به‌کارگیری ربات‌ها به جای انسان‌ها، قدرتمند شدنِ قدرت‌های جهانی، به مخاطره افتادن ارزش‌های اخلاقی و اجتماعی با جایگزینی سیستم‌های هوشمند به جای انسان‌ها و مواردی دیگر مطرح شد. اما به‌مرور، طوفان احساسات افراطی و تفریطی درباره توسعه هوش مصنوعی و پیدایش چالش‌های اخلاقی اغراق‌آمیز فرو نشست، و نگاهی واقع‌بینانه و مستدل به توانایی‌ها و محدودیت‌های هوش مصنوعی نزد بسیاری از طراحان، مهندسان و توسعه‌دهندگان این فناوری آشکار گردید. امروزه، این نگاه معتدل در قامت حوزه‌ای مطالعاتی، مسائل و چالش‌های اخلاقی مرتبط با هوش مصنوعی را از منظر اخلاق فناوری صورت‌بندی می‌کند، آن‌ها را تحلیل و تبیین می‌نماید، و سرانجام به معرفی و تدوین رهنمودهایی اخلاقی برای

توسعه هوش مصنوعی می‌پردازد (عبد خدایی و همکاران ۱۴۰۰، ۱۵-۱۶).

هدف این مقاله معرفی اصول و تدوین رهنمودهای اخلاق هوش مصنوعی با مطالعه هفت سند ملی و بین‌المللی است. در این مقاله، برای دستیابی به این هدف، پنج اصل اخلاقی یکپارچه «فلوریدی» مبنای گردآوری و بررسی رهنمودهای اخلاق هوش مصنوعی قرار می‌گیرد و این رهنمودها در سه مرحله بررسی می‌شوند. در مرحله اول، رهنمودهای اخلاقی اسناد مذکور استخراج و فهرست می‌شوند. در مرحله دوم، رهنمودهای گردآوری‌شده، یکدست‌سازی و پالایش می‌شوند. در مرحله سوم، برای ارزیابی روایی یافته‌ها و دستاورد پژوهش، رهنمودهای اخلاقی پالایش‌شده ذیل اصول اخلاقی پنج‌گانه توسط گروهی کانونی از متخصصان هوش مصنوعی، فلسفه و اخلاق تکنولوژی و علم اطلاعات نقد و بررسی می‌شود تا فرایند اعتباربخشی به رهنمودهای اخلاقی برگزیده با دستیابی به اِجماعی نسبی میان متخصصان تحقق یابد. در نهایت، اصول اخلاقی خیرخواهی با ۷ رهنمود، عدم آسیب‌رسانی با ۱۲ رهنمود، خودمختاری با ۷ رهنمود، عدالت با ۱۰ رهنمود، و توضیح‌پذیری با ۱۰ رهنمود دستاوردهای این پژوهش هستند.

۲. پیشینه پژوهش

سرآغاز حوزه مطالعاتی هوش مصنوعی را می‌توان به «آلن تورینگ»[1]، دانشمند علوم محاسباتی و مبدع الگوریتم رمزگشایی از ماشین رمزگذار آلمانی‌ها (به‌نام انیگما[2]) در جنگ جهانی دوم ارجاع داد. او در سال ۱۹۵۰، در مقاله‌ای که با عنوان «دستگاه محاسبات و هوش» در مجله Mind منتشر شد، برای نخستین‌بار به مفهوم هوش ماشین اشاره کرد و ادعا کرد که ماشین‌ها هم می‌توانند مانند انسان فکر کنند. در ۱۹۵۶، در کنفرانس دارتموث اصطلاح هوش مصنوعی توسط «جان مک‌کارتی»[3] دانشمند علوم محاسباتی و علوم شناختی به‌کار برده شد. در این کنفرانس «هربرت سایمون»[4] و «آلن نیوول»[5] برنامه‌ای ارائه کردند که با استفاده از هوش مصنوعی و بهره‌گیری از زیربناهای منطق ریاضی می‌توانست قضیه‌های اصولی ریاضیات را اثبات کند. از ۱۹۷۰ تا ۱۹۸۰، محققان، سیستم‌های هوشمند بیشتری

1. Alan Turing
2. Enigma
3. John McCarthy
4. Herbert Simon
5. Allen Newell

با کاربرد در زیست‌شناسی، پزشکی، مهندسی، و صنایع نظامی طراحی کردند. در سال ۲۰۰۰، یادگیری ماشین آماری که از دهه ۸۰ میلادی آغاز شده بود، کاربردهای گسترده‌ای در خدمات نرم‌افزاری و دستگاه‌های موبایل پیدا کرد. در سال ۲۰۰۹، دانشگاه استنفورد «انجمن پیشبرد هوش مصنوعی»[1] را برای مطالعه آینده هوش مصنوعی پایه‌گذاری کرد. امروزه، در ادامه تحولات مستمر هوش مصنوعی، ربات چت هوش مصنوعی با عنوان ChatGPT گسترش و توسعه یافته است. این ربات توسط شرکت OpenAI توسعه یافته است. این شرکت در سال ۲۰۱۵ تأسیس شد و از سوی سرمایه‌گذارن بزرگی همچون مایکروسافت پشتیبانی می‌شود. ربات ChatGPT یک سرویس مبتنی بر متن است که پاسخ‌هایی شبیه به انسان برای درخواست‌ها و پرسش‌های کاربر فراهم می‌کند. این ربات به هر سؤال پاسخ داده و به‌معنای واقعی کلمه همه‌فن‌حریف است (بهاری ۱۳۹۸، ۲۱-۲۴). اگرچه این تحولاتِ هر روزه، در حوزه هوش مصنوعی و امکانات و ابزارهای مبتنی بر آن همچنان ادامه دارد، اما به موازات این توسعه، حساسیت‌ها و ملاحظات اخلاقی گوناگونی شکل می‌گیرند. به بیان دیگر، هر اندازه که ماشین‌های هوشمند بتوانند به‌طور فعال با انسان‌ها در تعامل باشند، به همان اندازه می‌توانند موقعیت‌های اخلاقی پیچیده و گاهی نوظهور ایجاد کرده و نقش مؤثری ایفا کنند. امروزه، ویژگی‌ها و کارکردهای انسانی به ربات‌های هوشمند انتقال داده می‌شوند و به‌دنبال آن در موقعیت‌های اخلاقی، نقش مشابه یک انسان برای آن‌ها در نظر گرفته می‌شود. به‌عنوان مثال، یک پرستار در قبال بیمار خود مسئولیت‌های اخلاقی مشخصی دارد. حال اگر همین پرستار یک ربات هوشمند باشد، آیا همان مسئولیت‌های اخلاقی بر عهده این ربات هوشمند هم خواهد بود؟

در پاسخ به این پرسش می‌توان سه رویکرد را اتخاذ کرد: رویکرد اول) این‌گونه موقعیت‌ها برای ماشین هوشمند، اخلاقی محسوب نمی‌شود و اگر به این‌گونه شرایط صفت اخلاقی نسبت دهیم، از اساس دچار خطا شده‌ایم. رویکرد دوم) چنین موقعیتی شبه‌اخلاقی[2] است؛ به این معنا که بخشی از آن اخلاقی بوده، اما عامل‌های هوشمند ماشینی در این شرایط فاقد ویژگی‌های به‌خصوصی هستند که یک عامل اخلاقی تام[3] باید واجد آن باشد. بنابراین، هرچند می‌توان آن‌ها را به‌نوعی عامل اخلاقی در نظر گرفت، ولی عامل

1. Association for the Advancement of Artificial Intelligence (AAAI)
2. pseudo-moral
3. full moral agent

اخلاقی تـام محسـوب نمی‌شـوند. رویکـرد سـوم) چنیـن موقعیـتی اخلاقی محسـوب می‌شـود و بایـد به‌طـور جـدی و به‌عنـوان یـک مسـئله اخلاقی بـه آن نگریسـت.

پیرامـون ایـن رویکردهـای سـه‌گانه، مجموعـه آثـار و دیدگاه‌هـای مختلـفی در اخلاق هـوش مصنـوعی گـردآوری و اتخـاذ شـده اسـت. در سـال‌های اخیـر رشـد و انباشـت منابـع تخصـصی در ایـن حـوزه از چنـان شـتابی برخـوردار شـده اسـت کـه مـروری بـر کتاب‌هـا و مجموعـه مقـالات گردآوری‌شـده صرفاً در چنـد سـال اخیـر، گـواه اهمیـت ایـن حـوزه مطالعـاتی و پرداختـن بـه مسـائل و چالش‌هـای اخلاقی مرتبـط اسـت. در ادامـه بـه معـرفی بـرخی از ایـن آثـار پرداختـه می‌شـود.

«پائـولا بودینگتـون» در کتـاب خـود «به‌سـوی کدنامـه‌ای اخلاقی بـرای هـوش مصنـوعی»، بـا توجـه بـه سـرعت روزافـزون شـکل‌گیری مسـائل اخلاقی فعلـی و آتی در توسـعه هـوش مصنـوعی، بـه بـررسی چگونـگی تهیـه و تدویـن کدهـا یـا مقـررات اخلاقی واقـعی و قابـل اجـرا در ایـن زمینـه می‌پـردازد. او در ایـن اثـر ملاحظـات اخلاقی کلیـدی را به‌اختصـار بیـان می‌کنـد، همـه جوانـب اسـتدلال‌ها را آشـکار می‌سـازد، و بـه چگونـگی تدویـن کدهـای اخلاقی می‌پـردازد (Boddington 2017). ایـن کتـاب منبـع مفیـدی بـرای کسـانی اسـت کـه قصـد دارنـد چالش‌هـای اخلاقی پژوهش‌هـای هـوش مصنـوعی را بـه روش‌هـایی معنـادار و عمـلی بـررسی و مطالعـه کننـد.

«مـارک کوکلبـرگ» در کتـاب «اخلاق هـوش مصنـوعی»، به‌عنـوان یـک فیلسـوف فنـاوری، فراتـر از سـناریوهای ژورنالیسـتی و عامه‌پسـند، روایت‌هـای قابـل تأمـلی از هـوش مصنـوعی را توصیـف می‌کنـد؛ از هیـولای فرانکنشـتاین[1] تـا فراانسـان‌گرایی[2] و تکینـگی فناورانـه[3]. وی بحث‌هـای فلسـفی متعـدد مرتبـطی را بـررسی می‌کنـد و پرسـش‌هایی دربـاره تفاوت‌هـای اسـاسی بیـن انسـان و ماشیـن و بحث‌هـایی دربـاره وضعیـت اخلاقی هـوش مصنـوعی پیـش می‌آوَرد. او فناوری‌هـای هـوش مصنـوعی را توضیـح می‌دهـد و رویکردهـای مختلـف آن را توصیـف کـرده و بـر حوزه‌هـای یادگیـری ماشیـن و علـم داده تمرکـز می‌کنـد. در ایـن اثـر مـروری بـر مسـائل مهـم اخلاقی، از جملـه نگرانی‌هـای مربـوط بـه حریـم خصـوصی، مسـئولیت و تفویـض اختیـار

1. Frankenstein's monster

2. transhumanism

۳. technological singularity اصـطلاح سینگولاریـتی تکنولوژیـکی یـا تکینـگی فناورانـه بـه نقطـه‌ای فـرضی در آینـده اشـاره دارد کـه در آن رشـد هـوش مصنـوعی از تـوان شـناختی انسـان پیـشی می‌گیـرد و سـپس پیشـرفت فنـاوری به‌صـورت نمـایی، غیرقابـل پیش‌بینـی و خـارج از کنتـرل انسـانی ادامـه می‌یابـد

تصمیم‌گیری، شفافیت و سوگیری در تمامی مراحل فرایندهای علم داده ارائه می‌شود. در این اثر همچنین آینده کار در اقتصاد هوش مصنوعی بررسی می‌گردد. در نهایت، نویسنده طیفی از پیشنهادهای سیاستی را تجزیه‌وتحلیل می‌کند و چالش‌های پیش‌رِوی سیاست‌گذاران در این حوزه را بحث و بررسی می‌کند. در پایان، وی به دفاع از رویّه‌های اخلاقی می‌پردازد که ارزش‌های تعبیه‌شده در طراحی‌های فناورانه را به ارزش‌های دموکراتیک درون رویّه‌ها تبدیل می‌کند و استدلال می‌کند که از این راه به چشم‌اندازی از زندگی خوب و جامعه خوب دست می‌یابیم (Coeckelbergh 2020).

در اثری با نام «مقدمه‌ای بر اخلاق در رباتیک و هوش مصنوعی»، مخاطبان با مبانی هوش مصنوعی و اخلاق آشنا می‌شوند. در این اثر درباره مسائل اعتماد، مسئولیت‌پذیری، حریم خصوصی و مخاطرات در رابطه با هوش مصنوعی بحث می‌شود. محتوای این کتاب به‌گونه‌ای ارائه شده است که مخاطبان نیاز گسترده‌ای به تخصص فنی، حقوقی یا فلسفی نیاز ندارند. نویسندگان از مثال‌های متعددی برای بیان مسائل و چالش‌های اخلاقی استفاده می‌کنند و کتاب را با بحث در زمینه‌های کاربردی هوش مصنوعی و رباتیک، به‌ویژه وسایل نقلیه خودران، سیستم‌های تسلیحات خودکار و الگوریتم‌های سوگیرانه به پایان می‌رسانند (Bartneck & et al. 2021).

در اثر دیگری از «پائولا بودینگتون» که در قالب کتابی درسی با عنوان «اخلاق هوش مصنوعی» تدوین شده است، مخاطبان با دغدغه‌های اخلاقی مهمی در توسعه و استفاده از هوش مصنوعی آشنا می‌شوند. او با ارائه اطلاعاتی روشن و قابل فهم درباره مفاهیم و موضوعات اصلی در اخلاق هوش مصنوعی، به بررسی این مسئله می‌پردازد که چالش‌های اخلاقی فعلی مرتبط با توسعه هوش مصنوعی چگونه ما را وادار می‌کنند که به پرسش‌های اساسی و قدیمی درباره زندگی انسان، ارزش و معنا بپردازیم. افزون بر این، این کتاب نشان می‌دهد که چگونه مسائل بنیادی و نظری در حوزه اخلاق با مناقشات عینی اخلاقی در حوزه هوش مصنوعی مرتبط هستند. در ادامه، پرسش‌های مربوط به اخلاق هوش مصنوعی در زمینه موضوعات مرتبط با فناوری، مقررات، جامعه، مذهب و فرهنگ بررسی می‌شوند تا درک روشنی از حوزه اخلاق هوش مصنوعی به خوانندگان عرضه شود (Boddington 2022).

در کتاب «اخلاق هوش مصنوعی: مطالعات موردی و گزینه‌هایی برای رسیدگی به چالش‌های اخلاقی»، نویسندگان، این مجموعه را با هدف دسترسی مطلوب به مطالعات

موردی در حوزه اخلاق هوش مصنوعی گردآوری کرده‌اند. از این‌رو، اولین کتابی است که مطالعات موردی زندگی واقعی را همراه با تفسیرها و راهبردهایی برای غلبه بر چالش‌های اخلاقی ارائه می‌کند. مطالعات موردی یکی از بهترین روش‌ها برای فهم چالش‌های اخلاقی هوش مصنوعی و دستیابی به بینشی مناسب درباره پیچیدگی‌های مختلف و دیدگاه‌های بهره‌داران این چالش‌هاست. با توجه به حضور همه‌جانبه اخلاق هوش مصنوعی در بحث‌های دانشگاهی، سیاست‌گذاری، و رسانه‌ای، این کتاب برای طیف وسیعی از مخاطبان، از محققان رشته‌های مختلف (مانند علم هوش مصنوعی، اخلاق، سیاست، فلسفه، اقتصاد) گرفته تا مدیران و سیاست‌گذاران مناسب خواهد بود (Stahl, Schroeder & Rodrigues 2022).

در کتاب «اخلاق هوش مصنوعی برای اهداف توسعه پایدار»، نویسندگان شامل متخصصانی هستند که با دیدگاه‌هایی از حوزه‌های مختلف به گردآوری این مجموعه پرداخته‌اند. در فصل‌های مختلف این مجموعه، مشکلات حاد حاکمیتی مربوط به استفاده از هوش مصنوعی برای اهداف توسعه پایدار معرفی و مطالعاتی موردی درباره اینکه چگونه هوش مصنوعی در حالِ پیشرفت می‌تواند به اهداف توسعه پایدار دست یابد، بحث و بررسی می‌شود. محققانی که در رابطه با هوش مصنوعی برای اهداف توسعه پایدار و حاکمیت اخلاقی هوش مصنوعی پژوهش می‌کنند، مخاطبان اصلی این اثر هستند (Mazzi & Floridi 2023).

آثار معتبر و روزآمد فوق تنها نمونه بسیار اندکی از اسناد، دستورالعمل‌ها، مقالات و دیگر منابع تخصصی در حوزه اخلاق هوش مصنوعی هستند که ضرورت شناسایی و اهمیت تدوین اصول و رهنمودهای اخلاقی برای مواجهه با چالش‌های اخلاقی در توسعه هوش مصنوعی را آشکار می‌کنند.

۳. روش پژوهش

همان‌گونه که اشاره شد، هدف این مقاله معرفی اصول و تدوین رهنمودهای اخلاقی هوش مصنوعی با مطالعه هفت سند ملی و بین‌المللی است. در این مقاله برای دستیابی به این هدف، پنج اصل اخلاقی یکپارچه «لوچیانو فلوریدی»[1]، فیلسوف معاصر فلسفه و اخلاق

1. Floridi & Cowls

اطلاعـات، مبنـای گـردآوری و بـررسی رهنمودهـای اخلاق هـوش مصنـوعی قـرار می‌گیـرد و در سـه مرحلـه بـررسی می‌شـود. در مرحلـه اول، رهنمودهـای اخلاقی اسـناد مذکـور اسـتخراج و فهرسـت می‌شـوند. در مرحلـه دوم، رهنمودهـای گردآوری‌شـده یکدست‌سـازی، مـوارد تکـراری حـذف، و رهنمودهـای جزئی‌تـر بـه نفـع رهنمودهـای کلی‌تـر کنـار گذاشـته می‌شـوند. در مرحلـه سـوم، بـرای ارزیـابی روایی یافته‌هـا و دسـتاورد پژوهـش، رهنمودهـای اخلاقی پالایش‌شـده ذیـل اصـول اخلاقی پنج‌گانـه توسـط گـروهی کانـونی از متخصصـان هـوش مصنـوعی، فلسـفه و اخلاق فنـاوری و علـم اطلاعـات نقـد و بـررسی می‌شـود. ایـن بررسی‌هـا تـا زمـان دسـتیابی بـه اِجمـاعی نسـبی میـان متخصصـان گـروه کانـونی ادامـه داشـته و فراینـد اعتباربخشـی بـه یافته‌هـای پژوهـش تحقـق می‌یابـد.

٤. معرفی اصول اخلاقی یکپارچه برای اخلاق هوش مصنوعی

حـوزه مطالعـاتی اخلاق هـوش مصنـوعی اغلـب بـر انـواع مختلـفی از چالش‌هـای اخلاقی و اجتمـاعی نـاشی از توسـعه و اسـتقرار سیسـتم‌های هـوش مصنـوعی متمرکـز اسـت و دربردارنـده مجموعـه‌ای از ملاحظـات و پاسـخ‌هایی نقادانـه بـه چالش‌هاسـت. البتـه طیـف وسیـعی از ایـن چالش‌هـا اغراق‌آمیـز یـا دسـت کـم مسـائلی اخلاقی هسـتند کـه نوظهـور نیسـتند و پیـش از پیدایـش مصنوعـات مرتبـط بـا هـوش مصنـوعی وجـود داشـته‌اند و صرفـاً بازآفرینـی یـا تشـدید شـده‌اند. امـا بـرخی از آن‌هـا در حقیقـت، منبعـث از توسـعه و اسـتقرار سیسـتم‌های هـوش مصنـوعی هسـتند. تفکیـک میـان ایـن دو دسـته چالش‌هـای ظاهـری و حقیـقی نیازمنـد تحلیـل و بـررسی نقادانـه و موشـکافانه اسـت.

مرامنامه‌هـا یـا اسـناد اخلاقی بـرای توسـعه و اسـتقرار هـوش مصنـوعی بـه مجموعـه‌ای از اصـول اخلاقی و رهنمودهـای اخلاقی گفتـه می‌شـود کـه در چارچـوب اخلاق کاربـردی بـرای مواجهـه بـا چالش‌هـای اخلاقی و اجتمـاعی نـاشی از طـراحی، توسـعه و اسـتقرار سیسـتم‌های هـوش مصنـوعی گـردآوری، تبییـن و اسـتنتاج می‌شـود. ایـن مرامنامه‌هـا یـا اسـناد اخلاقی به‌طـور معمـول، بـا اِجمـاعی سـازمانی یـا نهـادی ضمانـت اجـرایی می‌یابنـد. بنابرایـن، آن‌هـا را می‌تـوان در قالـب اسـناد مـلی یـا بین‌المللی در رابطـه بـا اخلاق هـوش مصنـوعی بـه تصویـب رسـانده و اجـرایی کـرد. ایـن اسـناد به‌گفتـه دیگـر، مجموعـه‌ای از اصـول و رهنمودهـای اخلاقی مرتبـط بـا اخلاق هـوش مصنـوعی اسـت کـه بـا همـکاری میـان مهندسـان هـوش مصنـوعی، محققـان اخلاق، روان‌شناسـان، جامعه‌شناسـان، حقوق‌دانـان، سیاسـت‌گذاران و بـرخی دیگـر از متخصصـان

مرتبط با این حوزه برای مواجهه اخلاقی در توسعه و استقرار سیستم‌های هوشمند در سطح ملی، منطقه‌ای و جهانی گردآوری و ارائه می‌شود (Gordon & Wrenn 20).

از این‌رو، در چند دهه اخیر با رشد روزافزون سیستم‌های هوش مصنوعی، نهادها و سازمان‌های با نفوذ ملی یا بین‌المللی (از جمله دولت‌ها، یونسکو، اتحادیه اروپا، شرکت‌ها و انجمن‌های تخصصی) وظیفه تهیه پیش‌نویس منشورها و رهنمودهای اخلاقی با هدف تحقق سیستم‌های هوش مصنوعی مفید برای جامعه را به گروه‌های متخصص در حوزه‌های مطالعاتی فنی، حقوقی، اجتماعی، اخلاقی مرتبط با هوش مصنوعی واگذار کرده‌اند. امروزه، چنین اسنادی به‌خاطر تعدد و تکثر سازمان‌ها و نهادهای ملی و بین‌المللی مرتبط با توسعه و استقرار اخلاقی سیستم‌های هوش مصنوعی به حدی گسترش یافته‌اند که در آن پیگیری آخرین اصول و رهنمودهای منتشرشده بسیار دشوار است. افزون بر این، سازمان‌های مرتبط با اخلاق هوش مصنوعی بودجه قابل توجهی از منابع مختلف دولتی و خصوصی دریافت می‌کنند و چندین مرکز تحقیقاتی برای این منظور تأسیس شده است. این تحولات به‌طور عمده، پاسخ‌های مثبتی دریافت کرده است. در همین حال، به‌خاطر تکثر اصول و رهنمودهای اخلاق هوش مصنوعی، نگرانی‌هایی نسبت به شست‌وشوی اخلاقی[1] فعالیت‌های پژوهشی و تکنولوژیکی ناصواب در شرکت‌های تخصصی وجود دارد[2]. اما یکی از مهم‌ترین پرسش‌های قابل طرح این است که آیا می‌توان میان اصول اخلاقی و به‌دنبال آن، میان رهنمودهای متفاوت در کدهای اخلاق هوش مصنوعی اتفاق نظر ایجاد کرد یا خیر (Gordon & Wrenn 2020).

هدف این مقاله معرفی اصول یکپارچه اخلاقی و تدوین رهنمودهای اخلاقی هوش مصنوعی با مطالعه هفت سند ملی و بین‌المللی در چارچوب این اصول اخلاقی است. برای دستیابی به این هدف، پنج اصل اخلاقی «لوچیانو فلوریدی»، فیلسوف معاصر فلسفه و اخلاق اطلاعات، مبنای گردآوری و بررسی رهنمودهای اخلاقی هوش مصنوعی قرار می‌گیرد. اهمیت معرفی اصول یکپارچه اخلاقی بدین‌خاطر است که به‌منظور گردآوری، تدوین، و پیشنهاد رهنمودهای اخلاقی هوش مصنوعی لازم است اصول بنیادینی که رهنمودهای

1. ethics washing

۲. اصطلاح شست‌وشوی اخلاق، به موقعیتی اشاره دارد که در آن، سازمان یا شرکت بیش از آنکه دغدغه ارتقای اخلاقی خدمات یا محصولات خود را داشته باشد، به‌دنبال ضربِ مُهر تأیید اخلاقی بر این فعالیت‌هاست، حال آنکه با نگاهی انتقادی‌تر و عمیق‌تر، فعالیت‌های سازمانی مذکور صرفاً از ظاهری اخلاقی برخوردار است

اخلاقی با استناد به آن‌ها تهیه و تنظیم می‌شوند، متمایز و معرفی شوند. در اینجا، با محور قرار دادن نتایج پژوهشی مقاله‌ای از «فلوریدی و کولز» با عنوان «چارچوبی یکپارچه از پنج اصل برای هوش مصنوعی در جامعه (Floridi & Cowl 2019)، در نظر داریم اصول اخلاقی یکپارچه و بنیادی برگرفته از این پژوهش را مبنای گردآوری و بررسی رهنمودهای اخلاقی هوش مصنوعی قرار دهیم.

برای پیشنهاد رهنمودهای اخلاقی، سازمان‌ها و نهادهای ملی و بین‌المللی متعددی اقدام به گردآوری و تدوین اصول اخلاقی هوش مصنوعی کرده‌اند. شوربختانه، حجم بالای اصول پیشنهادی انبوهی از این اصول و تهدیدی برای سردرگمی به بار آورده است. این وضعیت دو مسئله بالقوه را به‌وجود می‌آورد: اگر مجموعه‌های مختلفی از اصول اخلاقی برای هوش مصنوعی، مشابه یکدیگر باشند، این مسئله منجر به تکرار و افزونگی غیرضروری می‌شود؛ اما اگر آن‌ها به‌طور قابل توجهی متفاوت از همدیگر باشند، منجر به سردرگمی و ابهام می‌شود. در سال ۲۰۱۷، پس از انتشار اصول هوش مصنوعی «آسیلومار»[1] و اعلامیه مونترال برای توسعه مسئولانه هوش مصنوعی، بسیاری از سازمان‌ها و نهادهای ملی و بین‌المللی در جهت عمل به مسئولیت اجتماعی و البته تثبیت اقتدار نهادی خود، اقدامات وسیعی برای تدوین اصول اخلاقی هوش مصنوعی به‌عمل آورده‌اند. این اسناد اخلاقی عبارت‌اند از: ۱) اصول هوش مصنوعی «آسیلومار» (Future of Life Institute 2017)؛ ۲) بیانیه مونترال برای توسعه مسئولانه هوش مصنوعی (Université de Montréal 2018)؛ ۳) طراحی همسو: چشم‌اندازی برای اولویت دادن به رفاه انسان همراه با سیستم‌های خودگردان و هوشمند «مؤسسه مهندسان برق و الکترونیک» (IEEE 2017)؛ ۴) اصول اخلاقی بیانیه هوش مصنوعی، رباتیک و سیستم‌های خودگردان؛ گروه اروپایی کمیسیون اروپا در زمینه اخلاق در علم و تکنولوژی‌های نوظهور (High-Level Expert Group on Artificial Intelligence 2019)؛ ۵) پنج اصل کلی برای کدهای هوش مصنوعی در گزارش مجلس بریتانیا (House of Lords Select Committee on Artificial Intelligence 2018)؛ ۶) بیانیه اصول اخلاقی مؤسسه مشارکت در هوش مصنوعی (Partnership on AI 2016)؛ و ۷) توصیه‌نامه اخلاق هوش مصنوعی کنفرانس عمومی یونسکو (UNESCO 2021).

امروزه با حجم روزافزون اسنادِ اخلاق هوش مصنوعی، خطر تکرار و همپوشانی

1. Asilomar

غیرضروری در صورت مشابه بودن مجموعه‌های مختلف اصول، یا سردرگمی و ابهام در صورت متفاوت بودن آن‌ها پدیدار شده است. از نظر «فلوریدی و کولز» زمان آن فرا رسیده است که یک تحلیل مقایسه‌ای معطوف به این اسناد انجام شود. از موارد قابل بررسی در تحلیل آنان، ارزیابی این موضوع است که آیا این اصول اخلاقی متعدد همگرا هستند یا واگرا؟ و اگر همگرا باشند، می‌توان یک چارچوب واحد و یکپارچه برای این اصول تنظیم و ارائه کرد. در پژوهش آنان، این اسناد بر اساس چهار معیار اساسی انتخاب شده‌اند که عبارت‌اند از: الف) متأخر بودن؛ به این معنا که اسناد مذکور از سال ۲۰۱۷ به بعد منتشر شده‌اند؛ ب) به‌طور مستقیم مرتبط با هوش مصنوعی و تأثیر آن بر کلیت جامعه هستند؛ ج) بسیار معتبر هستند و از اقتدار نهادی ملی و بین‌المللی برخوردارند؛ و د) به‌دلیل دارا بودن ویژگی‌های الف تا ج تأثیرگذار هستند. بر این اساس، «فلوریدی و کولز» اسناد معرفی‌شده ۱ تا ۶ را از منظر همگرایی یا واگرایی اصول اخلاقی مندرج در آن‌ها، و در صورت همگرایی آن‌ها، ارائه چارچوب یکپارچه‌ای از اصول اخلاقی که غیرقابل فروکاست به یکدیگر هستند، بررسی تحلیلی و نقادانه کردند (Floridi & Cowls 2019).

به‌طور کلی، ۶ سند نخست، نزدیک به ۴۷ اصل را ارائه می‌کنند. اگرچه، تفاوت‌ها در این اصول به‌طور عمده زبانی هستند و درجه‌ای از هماهنگی و همپوشانی قابل توجهی بین این اصول متعدد و متکثر وجود دارد. در نهایت، نتیجه بررسی‌های آنان به معرفی ۵ اصل اخلاقی یکپارچه، مجزا و غیرقابل فروکاست به یکدیگر منجر می‌شود. در شکل ۱، اصول اخلاقی مذکور نشان داده شده است.

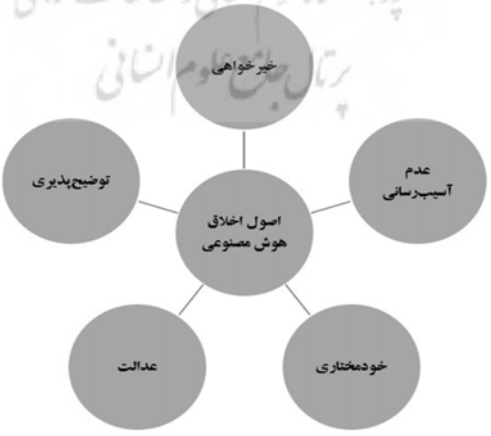

شکل ۱. پنج اصل اخلاقی مجزا و یکپارچه اخلاق هوش مصنوعی از دیدگاه «فلوریدی و کولز»

همان‌گونه که اشاره شد، برای اجتناب از تکرار و افزونگی غیرضروری در تکثر و تنوع اصول اخلاقی از سویی، و رفع سردرگمی و ابهام ناخواسته در تعاریف همپوشانی‌کننده در اصول اخلاقی از سوی دیگر، ما را به پنج اصل اخلاقی برگرفته از تحقیقات «فلوریدی و کولز» رهنمون ساخت. اکنون ذیل این اصول پنج‌گانه اخلاقی، رهنمودهای هفت سند اخلاق هوش مصنوعی را بررسی و به‌ترتیب در سه مرحله به گردآوری، پالایش، و اعتباربخشی آن‌ها می‌پردازیم.

برای تحقق مراحل سه‌گانه فوق ابتدا لازم است این اصول اخلاقی پنج‌گانه، فهرست شده، قلمرو مفهومی آن‌ها مشخص گردد، و برای آن‌ها تعریفی صریح ارائه شود. از این طریق رهنمودهای اخلاقی را در سه مرحله این پژوهش به نحوی دقیق‌تر مورد بررسی قرار می‌دهیم. در جدول ۱، هر اصل اخلاقی تعریف شده و قلمرو مفهومی آن‌ها برای پرهیز از فروکاستِ به اصل اخلاقی دیگری مشخص شده است.

جدول ۱. تعریف پنج اصل اخلاقی و قلمرو مفهومی آن برای بررسی رهنمودهای اخلاق هوش مصنوعی

اصل اخلاقی	قلمرو مفهومی	تعریف
خیرخواهی[1]	ارتقای رفاه، حفظ کرامت و پایداری کره زمین	هوش مصنوعی برای خیر اجتماعی[2]، در خدمت منافع عمومی برای بشریت است و در نهایت، موجب ارتقای رفاه و حفظ کرامت انسانی و پایداری محیط زیست می‌شود.
عدم آسیب‌رسانی[3]	حریم خصوصی، امنیت و احتیاط	هوش مصنوعی برای خیر اجتماعی، موجب نقض حریم خصوصی و امنیت انسان‌ها نمی‌شود و از توانمندی آن علیه بشریت استفاده نمی‌گردد.
خودمختاری[4]	قدرت تصمیم‌گیری برای تصمیم‌گیری	هوش مصنوعی برای خیر اجتماعی، حق انتخاب و قدرت تصمیم‌گیری انسان‌ها را محدود یا دچار اختلال نمی‌کند، بلکه موجب ارتقای آن‌ها می‌شود.
عدالت[5]	گسترش رفاه، حفظ همبستگی، اجتناب از بی‌عدالتی	هوش مصنوعی برای خیر اجتماعی، در جهت گسترش رفاه، حفظ همبستگی[6] و اجتناب از تبعیض‌ها، فرصت دسترسی برابر به رفاه و منافع مشترک برای انسان‌ها را فراهم می‌آورد.
توضیح‌پذیری[7]	امکان‌پذیری دیگر اصول از طریق درک‌پذیری و پاسخگویی	هوش مصنوعی برای خیر اجتماعی، دارای فرایندهایی شفاف است؛ به‌نحوی که قابلیت‌ها و هدف این سیستم‌ها را به‌طور شفاف به یکدیگر مرتبط می‌کند و تصمیمات این سیستم‌ها تا حد امکان برای افرادی که به‌صورت مستقیم یا غیرمستقیم تحت تأثیر آن‌ها قرار می‌گیرند، قابل توضیح است.

1. beneficence
2. AI for social good: AI4SG
3. nonmaleficence
4. autonomy
5. justice
6. solidarity
7. explicability

۵. تجزیه‌وتحلیل هفت سند اخلاق هوش مصنوعی

تاکنون به معرفی ۵ اصل اخلاقی یکپارچه پرداخته شده است. اکنون در نظر داریم با فهرست کردن هفت سند ملی و بین‌المللی در حوزه اخلاق هوش مصنوعی با معیارهای اعتبارسنجی که در قسمت ۴ به آن‌ها اشاره شد، ذیل اصول اخلاقی مذکور، رهنمودهای اخلاقی این اسناد را استخراج و ارزیابی کنیم. این رهنمودها در سه مرحله گردآوری، پالایش، و اعتباربخشی بررسی می‌شوند. ابتدا لازم است یادآوری شود که ۶ سند نخست از اسناد اخلاق هوش مصنوعی در قسمت ۴، همان اسنادی هستند که «فلوریدی» در تحقیق خود مبنای استخراج ۵ اصل اخلاقی قرار داده بود و به رهنمودهای اخلاقی آن‌ها، در صورت وجود، نپرداخته بود. سند هفتم به این مجموعه اسناد در این مقاله، به‌دلیل اهمیت، روزآمدی، اعتبار و جهان‌شمولی آن افزوده شده است. این سند در واقع، توصیه‌نامه‌ای مبسوط در خدمت اخلاق هوش مصنوعی است که در جلسه چهل‌ویکم کنفرانس عمومی یونسکو پس از بحث و بررسی نمایندگان کشورهای عضو، در نوامبر ۲۰۲۱ به تصویب رسید و به‌عنوان سندی مشورتی در اختیار کشورها قرار گرفت.

در مرحله اول ارزیابی، رهنمودهای اخلاقی اسناد مذکور استخراج و فهرست می‌شوند. در مرحله دوم، رهنمودهای گردآوری‌شده یکدست‌سازی، موارد تکراری حذف، و رهنمودهای جزئی‌تر به‌نفع رهنمودهای کلی‌تر کنار گذاشته می‌شوند. در مرحله سوم، برای ارزیابی روایی یافته‌ها و دستاورد پژوهش، رهنمودهای اخلاقی پالایش‌شده ذیل اصول اخلاقی پنج‌گانه توسط گروهی کانونی از متخصصان هوش مصنوعی، فلسفه و اخلاق فناوری و علم اطلاعات نقد و بررسی می‌شود. این بررسی‌ها تا زمان دستیابی به اِجماعی نسبی میان متخصصان گروه کانونی ادامه یافته و فرایند اعتباربخشی به یافته‌های پژوهش تحقق می‌یابد.

۵-۱. مرحله اول: استخراج رهنمودهای اخلاقی از هفت سند اخلاق هوش مصنوعی

رهنمودهای اخلاقی در بررسی هفت سند اخلاق هوش مصنوعی از طریق جست‌وجوی کلمات کلیدی یکسان و مشابه برای هر یک از اصول اخلاقی پنج‌گانه استخراج و گردآوری شدند. به‌عنوان مثال، برای اصل خیرخواهی، افزون بر واژه کلیدی beneficence و مشتقات و مترادف‌های آن، و کلماتی مانند dignity، wellbeing و sustainability نیز در تمامی این اسناد جست‌وجو شدند و رهنمودهایی که برخوردار از این واژه‌های کلیدی

بودنـد، اسـتخراج و گـردآوری شـدند. در مجمـوع، ۱۳۰ رهنمـود ذیـل ۵ اصـل اخلاقی از ۷ سـند اخلاق هـوش مصنـوعی اسـتخراج شـدند. ۱۵ رهنمـود بـرای اصـل خیرخـواهی، ۴۹ رهنمـود بـرای اصـل عـدم آسیب‌رسـانی، ۲۵ رهنمـود بـرای اصـل خودمختـاری، ۲۸ رهنمـود بـرای اصـل عدالـت، و ۲۸ رهنمـود بـرای اصـل توضیح‌پذیـری از ایـن اسـناد گـردآوری شـدند.

۵-۲. مرحله دوم: یکدست‌سازی و پالایش رهنمودهای گردآوری‌شده

در مرحلـه دوم، رهنمودهـای ویرایـش از نظـر اصطلاحـات یکدست‌سـازی شـدند. همچنیـن رهنمودهـای تکـراری حـذف و رهنمودهـایی کـه از جامعیـت کمتـری نسـبت بـه رهنمودهـای دیگـر برخـوردار بودنـد، حـذف شـدند. بـه ایـن ترتیـب، در مجمـوع، ۶۷ رهنمـود در قالـب ۸ رهنمـود بـرای اصـل خیرخـواهی، ۱۶ رهنمـود بـرای اصـل عـدم آسیب‌رسـانی، ۱۳ رهنمـود برای اصـل خودمختـاری، ۱۴ رهنمـود بـرای اصـل عدالـت، و ۱۶ رهنمـود بـرای اصـل توضیح‌پذیـری حفـظ شـدند. در مرحلـه بعـد، رهنمودهـای موجـود بـرای ارزیـابی و اعتباریـابی در گـروه کانـونی از متخصصـان مـورد بحـث و بـررسی قـرار گرفتنـد.

۶. یافته‌های پژوهش: مرحله سوم و برگزاری گروه کانونی اخلاق هوش مصنوعی

در ایـن مرحلـه رهنمودهـای اخلاقی به‌دسـت‌آمده از مرحلـه دوم در گـروه کانـونی بحـث و بـررسی گردیـد. ایـن گـروه شـامل ۶ نفـر متخصـص در حـوزه هـوش مصنـوعی و اخلاق حرفـه‌ای (دو متخصـص علـم اطلاعـات و دانش‌شـناسی، یـک متخصـص فلسـفه علـم و فنـاوری، یـک متخصـص مهنـدسی فنـاوری اطلاعـات، یـک متخصـص مهنـدسی صنایـع، و یـک متخصـص سیاسـت‌گذاری بـر پایـه مـدل) برگـزار شـد. در ایـن نشسـت، ۶۷ رهنمـود اخلاقی مرحلـه دوم در چارچـوب پنـج اصـل اخلاقی بـار دیگـر اولویت‌بخـشی، اصلاح و صورت‌بنـدی شـدند. در جـدول ۲، اصـول اخلاقی و رهنمودهـای پیشـنهادی در گـروه کانـونی ایـن پژوهـش، جمع‌بنـدی و فهرسـت می‌شـود.

جدول ۲. اصول و رهنمودهای پیشنهادی در اخلاق هوش مصنوعی

ردیف	اصل اخلاقی	رهنمودهای اخلاقی مرتبط
۱	خیرخواهی (با ۷ رهنمود)	◇ سیستم‌های هـوش مصنوعـی بایـد به‌گونـه‌ای توسـعه و اسـتقرار یابنـد کـه رفـاه انسـانی را به‌عنـوان پیامـد طراحـی ایـن سیسـتم‌ها تضمیـن کنـد. ◇ سیسـتم‌های هـوش مصنوعـی بایـد به‌گونـه‌ای توسـعه و اسـتقرار یابنـد

ردیف	اصل اخلاقی	رهنمودهای اخلاقی مرتبط
		که با خیر اجتماعی و پایداری محیط زیست در تعارض قرار نگیرند.
		◇ سیستم‌های هوش مصنوعی باید به‌گونه‌ای توسعه و استقرار یابند که امکان رشد و بهبود برای رفاه تمام موجودات صاحب شعور[1] فراهم شود.
		◇ سیستم‌های هوش مصنوعی باید در خدمت منافع و توانمندسازی بیشترین افراد ممکن باشد.
		◇ سیستم‌های هوش مصنوعی باید به‌گونه‌ای توسعه و استقرار یابند که با آرمان‌های کرامت انسانی، حقوق بشر، آزادی‌ها، خیر عمومی و تنوع فرهنگی سازگار باشند.
		◇ فرایندهای توسعه و استقرار سیستم‌های هوش مصنوعی باید ذیل چارچوب‌های حکمرانی (شامل استانداردها و نهادهای نظارتی) ارزیابی و ردیابی شوند تا حقوق، آزادی‌ها، کرامت، و حریم خصوصی انسان‌ها را نقض نکنند.
		◇ ارزیابی تأثیرات اجتماعی، اقتصادی، زیستی سیستم‌های هوش مصنوعی باید با آگاهی کامل از پیامدهای این تکنولوژی برای توسعه پایدار به‌گونه‌ای پیوسته و در حال تکامل انجام شود.
۲	عدم آسیب‌رسانی (با ۱۲ رهنمود)	◇ حریم خصوصی انسان‌ها در طول چرخه عمر سیستم‌های هوش مصنوعی باید به‌عنوان حقی ضروری برای حفاظت از کرامت انسانی، خودمختاری، و عاملیت انسانی رعایت، محافظت و ترویج شود.
		◇ توسعه سیستم‌های هوش مصنوعی باید در جهت ایجاد منافع اجتماعی و اقتصادی افراد از طریق کاهش نابرابری‌ها و آسیب‌پذیری‌های اجتماعی باشد.
		◇ سیستم‌های هوش مصنوعی باید در طول چرخه عمر خود ایمن و قابل اعتماد باشند و این ایمنی قابل تأیید باشد.
		◇ در تعامل با سیستم‌های هوش مصنوعی، افراد باید حق دسترسی، مدیریت، و کنترل بر داده‌های تولیدشده خود را داشته باشند.
		◇ سیستم‌های هوش مصنوعی باید در جمع‌آوری و بایگانی داده‌ها، حق محرمانگی داده‌ها و ناشناس‌بودن پروفایل‌های شخصی را تضمین کنند.
		◇ حریم خصوصی افراد باید از رخنه سیستم‌های هوش مصنوعی و سیستم‌های جمع‌آوری و بایگانی داده‌ها محافظت شود.
		◇ سیستم‌های هوش مصنوعی باید حق خلوت و امکان جدایی خودخواسته افراد از ارتباط و تعامل با آن‌ها را فراهم کنند.
		◇ در توسعه سیستم‌های هوش مصنوعی باید با حفظ احتیاط، پیامدهای منفی آن‌ها را به‌نحوی مسئولانه و تا حد امکان پیش‌بینی و اقدامات پیش‌گیرانه را اتخاذ کرد.
		◇ نسبت به خطرات بالقوه سوء استفاده از سیستم‌های هوش مصنوعی باید با ارائه آموزش‌های اخلاقی و امنیتی، حساسیت افراد جامعه را ارتقا داد.

1. entient beings

ردیف	اصل اخلاقی	رهنمودهای اخلاقی مرتبط
		◇ سیستم‌های هوش مصنوعی باید برای اطمینان از حفظ امنیت جسمی، ذهنی، و محیطی انسان‌ها، پیش از عرضه به دقت آزمایش شوند.
		◇ آسیب‌های ناخواسته (مخاطرات ایمنی) و همچنین آسیب‌پذیری در برابر حملات (مخاطرات امنیتی) از ابتدا تا پایان چرخه عمر سیستم هوش مصنوعی باید پیشگیری، رفع و حذف شوند تا ایمنی و امنیت انسانی و زیستی تضمین شود.
		◇ فرایندهای الگوریتمی در سیستم‌های هوش مصنوعی باید نسبت به نقض حریم خصوصی افراد ارزیابی شوند و رویکرد «حریم خصوصی از طریق طراحی» را مورد توجه قرار دهند.
۳	خودمختاری (با ۷ رهنمود)	◇ واگذاری امکان تصمیم‌گیری درباره انسان‌ها به سیستم‌های هوش مصنوعی باید با آگاهی از چگونگی و سپس پذیرش این فرایند مبتنی بر انتخاب خود این افراد باشد.
		◇ سیستم‌های هوش مصنوعی باید با احترام به خودمختاری افراد توسعه و استقرار یابند که هدف از آن، افزایش کنترل افراد بر زندگی و محیط پیرامونی خود است.
		◇ سیستم‌های هوش مصنوعی باید به افراد امکان دهند اهداف اخلاقی خود و درک شخصی خود از یک زندگی ارزشمند را تحقق بخشند.
		◇ سیستم‌های هوش مصنوعی باید به‌گونه‌ای توسعه و استقرار یابند که سبک زندگی خاصی را (به‌طور مستقیم یا غیرمستقیم) به افراد تحمیل نکنند.
		◇ توسعه و استفاده از سیستم‌های هوش مصنوعی نباید به هنگام ضرورت تصمیم‌گیری، به کاهش مسئولیت انسان‌ها منجر شود.
		◇ در سیستم‌های هوش مصنوعی هرگز نباید از قدرت خودگردانی خود برای آسیب زدن، نابود کردن یا فریب دادن انسان‌ها تعبیه شود.
		◇ افراد به دلایل تصمیم‌های سیستم‌های هوش مصنوعی که بر حقوق و آزادی‌های آنان تأثیر می‌گذارند باید دسترسی داشته باشند.
۴	عدالت (با ۱۰ رهنمود)	◇ سیستم‌های هوش مصنوعی باید به افراد امکان دهد از ظرفیت‌های ذهنی و جسمی خود استفاده کنند.
		◇ استفاده از سیستم‌های هوش مصنوعی نباید به افزایش استرس، اضطراب، یا احساس آزار از محیط دیجیتال برای افراد منجر شود.
		◇ سیستم‌های هوش مصنوعی نباید تهدیدی برای روابط اخلاقی و احساس رضایت‌بخش میان انسان‌ها باشد.
		◇ سیستم‌های هوش مصنوعی باید با هدف همکاری با انسان‌ها در وظایف پیچیده توسعه و استقرار یابند و کار گروهی میان انسان‌ها را تقویت کنند.
		◇ سیستم‌های هوش مصنوعی باید به گونه‌ای طراحی و آموزش داده شوند که باعث ایجاد، تقویت یا بازتولید تبعیض، بر اساس تفاوت‌های اجتماعی (جنسی، قومی، فرهنگی، یا مذهبی و دیگر موارد) نشوند.

ردیف	اصل اخلاقی	رهنمودهای اخلاقی مرتبط
		◇ سیستم‌های هوش مصنوعی نباید به‌گونه‌ای توسعه و استقرار یابند که جایگزین افراد در وظایفی شوند که نیازمند روابط باکیفیت انسانی است. ◇ سوگیری‌های تبعیض‌آمیز موجود در مجموعه داده‌هایی که برای آموزش و استقرار سیستم‌های هوش مصنوعی استفاده می‌شوند باید در سریع‌ترین زمان ممکن شناسایی، گزارش، و پالایش شوند. ◇ سیستم‌های هوش مصنوعی باید به‌گونه‌ای توسعه و استقرار یابند که عدالت اجتماعی را ارتقا دهند تا از انصاف و عدم تبعیض در هر شکلی مطابق با قوانین بین‌المللی محافظت کنند. ◇ سیستم‌های هوش مصنوعی باید به‌گونه‌ای توسعه و استقرار یابند که در طول چرخه عمر خود از تقویت یا استمرار کاربردها و نتایج تبعیض‌آمیز میان انسان‌ها اجتناب کنند. ◇ در سطح بین‌المللی، کشورهای پیشرفته از نظر فناوری مسئولیت همبستگی با کشورهای کمترپیشرفته را دارند تا اطمینان حاصل شود که منافع سیستم‌های هوش مصنوعی به‌گونه‌ای عادلانه به اشتراک گذاشته شود.
۵	توضیح‌پذیری (با ۱۰ رهنمود)	◇ هرگونه دخالت سیستم‌های هوش مصنوعی در تصمیم‌گیری‌های حیاتی باید شامل توضیحی رضایت‌بخش و قابل بررسی توسط یک مرجع انسانی معتبر باشد. ◇ هر فردی که از خدمات مبتنی بر سیستم‌های هوش مصنوعی استفاده می‌کند باید امکان آگاهی از این موضوع را داشته باشد که آیا تصمیمی مربوط به او یا تأثیرگذار بر او توسط یک سیستم هوش مصنوعی اتخاذ شده است یا خیر. ◇ هر فردی که از خدمات مبتنی بر چت‌بات‌ها استفاده می‌کند باید امکان تشخیص این موضوع را داشته باشد که آیا با یک سیستم هوش مصنوعی تعامل دارد یا خیر. ◇ سیستم‌های هوش مصنوعی باید به‌گونه‌ای توسعه و استقرار یابند که معیارهای فهم‌پذیری، توجیه‌پذیری، و دسترسی‌پذیری نسبت به تصمیم‌گیری‌های خود را تحت نظارت، بررسی، و کنترل انسانی و دموکراتیک تضمین کنند. ◇ سیستم‌های هوش مصنوعی باید به‌گونه‌ای توسعه و استقرار یابند که در صورت ایجاد آسیب به هر موجود صاحب شعوری، قابلیت ردیابی و کشف علت اصلی منشأ آن را داشته باشد. ◇ سیستم‌های هوش مصنوعی باید به‌گونه‌ای توسعه و استقرار یابند که تصمیم‌گیری‌های آن‌ها از شفافیت و پیش‌بینی‌پذیری مناسبی برخوردار باشد تا کاربران در صورت لزوم و مبتنی بر دلایلی اخلاقی در عملکرد آن‌ها مداخله کرده یا آن‌ها را متوقف کنند. ◇ فرایندها و مجموعه داده‌هایی که منجر به تصمیم‌گیری سیستم‌های هوش مصنوعی می‌شوند (از جمله مراحل جمع‌آوری داده‌ها، برچسب‌گذاری داده‌ها و الگوریتم‌های مورد استفاده) باید به بهترین شکل ممکن مستندسازی شود تا امکان ردیابی و ارتقای شفافیت در

ردیف	اصل اخلاقی	رهنمودهای اخلاقی مرتبط
		تصمیم‌های آن فراهم گردد. ◇ سیستم‌های هوش مصنوعی باید به‌گونه‌ای توسعه و استقرار یابند که اطلاعاتی درباره میزان تأثیرگذاری آن‌ها بر فرایند تصمیم‌گیری سازمانی، انتخاب‌های طراحی سیستم، و دلایل استفاده از آن در دسترس باشد. ◇ سیستم‌های هوش مصنوعی باید به‌گونه‌ای توسعه و استقرار یابند که قابلیت‌ها و محدودیت‌های آن‌ها به شکلی متناسب با کاربرد مورد نظر به متخصصان یا کاربران نهایی منتقل شود. ◇ آگاهی عمومی و فهم سیستم‌های هوش مصنوعی و ارزش داده‌ها باید از طریق آموزش‌های عمومی و قابل دسترس، مشارکت شهروندی، مهارت‌های دیجیتال، آموزش اخلاق هوش مصنوعی، سواد رسانه‌ای و اطلاعاتی و دیگر آموزش‌های مقتضی تقویت شود.

۷. نتیجه‌گیری

همان‌گونه که اشاره شد، هدف این مقاله معرفی اصول و تدوین رهنمودهای اخلاقی با مطالعه هفت سند ملی و بین‌المللی در حوزه اخلاق هوش مصنوعی بود. از آنجا که اصول و رهنمودهای اخلاقی در حوزه‌های متعدد اخلاق کاربردی (اخلاق پزشکی، اخلاق زیستی، اخلاق پژوهش، و مواردی دیگر) برآمده از تجربه‌ها و معرفت بشری است، به نظر می‌رسد که همراه با توسعه و استقرار فراگیر و جهانی سیستم‌های هوش مصنوعی، اصول و رهنمودهای اخلاق هوش مصنوعی نیز فارغ از مرزها و گستره‌های جغرافیایی برای تمام ساکنان زمین قابل استفاده و بهره‌برداری است.

از این‌رو، برای دستیابی به این هدف، پنج اصل اخلاقی یکپارچه «فلوریدی و کولز» مبنای گردآوری و بررسی رهنمودهای اخلاق هوش مصنوعی قرار گرفت. این پنج اصل اخلاقی عبارت‌اند از: خیرخواهی، عدم آسیب‌رسانی، خودمختاری، عدالت، و توضیح‌پذیری. در ادامه، هر یک از این اصول به‌طور دقیق تعریف و قلمرو مفهومی آن‌ها برای پرهیز از فروکاستِ به اصل اخلاقی دیگری مشخص گردید. پس از اصول اخلاقی پنج‌گانه، رهنمودهای هفت سند اخلاق هوش مصنوعی را ذیل این اصول، بررسی و به‌ترتیب در سه مرحله به گردآوری، پالایش، و اعتباربخشی آن‌ها پرداخته شد. در مرحله اول، رهنمودهای اخلاقی اسناد مذکور استخراج و فهرست شدند. در مرحله دوم، رهنمودهای گردآوری‌شده یکدست‌سازی، موارد تکراری حذف، و رهنمودهای جزیی‌تر به نفع رهنمودهای کلی‌تر کنار گذاشته شد. در مرحله سوم، برای ارزیابی روایی یافته‌ها

و دستاورد پژوهش، رهنمودهای اخلاقی پالایش‌شده ذیل اصول اخلاقی پنج‌گانه توسط گروهی کانونی از متخصصان هوش مصنوعی، فلسفه و اخلاق فناوری و علم اطلاعات نقد و بررسی گردید. این بررسی‌ها تا زمان دستیابی به اِجماعی نسبی میان متخصصان گروه کانونی به‌منظور جمع‌بندی و فهرست رهنمودهای پیشنهادی ادامه یافت. در نهایت، اصول اخلاقی خیرخواهی با ۷ رهنمود، عدم آسیب‌رسانی با ۱۲ رهنمود، خودمختاری با ۷ رهنمود، عدالت با ۱۰ رهنمود، و توضیح‌پذیری با ۱۰ رهنمود، دستاورد این پژوهش بود.

در پایان لازم است به سه نکته مهم اشاره شود: اول اینکه تهیه و تدوین رهنمودهای اخلاق هوش مصنوعی، به‌دنبال ارائهٔ راه‌حل نهایی و قطعی برای مسائل و دوراهی‌های اخلاقی بالقوه و پیچیده‌ای نیست که توسعه و استقرار سیستم‌های هوش مصنوعی بر سر راهِ بازیگرانِ درگیر در چرخهٔ حیات چنین سیستم‌هایی قرار می‌دهد. این اصول و رهنمودهای اخلاقی، در واقع، راهنمایی کلی و فراگیر است که به بازیگرانِ درگیر در این چرخهٔ حیات، چارچوبی برای ملاحظات اخلاقی موجه و تأملات استدلالی منسجم برای هر یک از چالش‌های متعدد اخلاقی فراهم می‌آورد. به بیان دیگر، اصول و رهنمودهای اخلاقی در این مقاله، نقش یک قطب‌نما را در مواجهه با مسائل و دوراهی‌های اخلاقی ناشی از توسعه و استقرار سیستم‌های هوش مصنوعی بازی می‌کند، نه اینکه نقشهٔ کامل راه باشد.

دوم اینکه گروه کانونی این پژوهش، رهنمودهای مورد بحث را با رویکرد اخلاق حرفه‌ای و تأکید بر قلمرو مخاطبان اصلی آن‌ها که شامل طراحان، متخصصان و توسعه‌دهندگان سیستم‌های هوش مصنوعی است، مبنای مباحث نقادانه خود قرار دادند. اما در صورت‌بندی نهایی تلاش شده است، این رهنمودهای اخلاقی، تمامی کنشگران و عامل‌های انسانی را که در چرخهٔ حیات این سیستم‌ها و توسعه و استقرار آن‌ها نقش‌آفرینی دارند، مخاطب قرار دهد. بی‌تردید، نقش طراحان، متخصصان و توسعه‌دهندگان سیستم‌های هوش مصنوعی برای توجه به رهنمودهای اخلاقی پیشنهادی به‌مراتب گسترده‌تر و مسئولانه‌تر است.

سوم اینکه در بررسی‌های گروه کانونی اخلاق در هوش مصنوعی، اصل عدم آسیب‌رسانی همچون بررسی اولیه هفت سند اخلاق هوش مصنوعی، از بیشترین رهنمودهای اخلاقی برخوردار شد. این موضوع، اهمیت عدم آسیب‌رسانیِ سیستم‌های هوش مصنوعی به جامعه انسانی و محیط زیست را نشان می‌دهد. از این رو، مطابق با رهنمودهای اخلاق هوش مصنوعی به نظر می‌رسد سیستم‌های هوش مصنوعی در طول چرخه عمر خود و در

فرایند توسعه و استقرارشان در سرتاسر کره زمین، پیش و بیش از هر دستاوردی، باید عدم آسیب رساندن به محیط زیست و موجودات صاحب شعورِ سکونت‌یافته در کره زمین را هدف نهایی خود قرار دهند.

فهرست منابع

بهاری، محمدرضا. ۱۳۹۸. *جادوی هومَص (مجموعه‌ای درباره هوش مصنوعی)*. تهران: مؤسسه پژوهشی مطالعات فرهنگی و اجتماعی.

عبدخدایی، زهره، نسیم توحیدی، نرگس کریمی، و محمد براتی. ۱۴۰۰. *هوش سفید: از اخلاق ماشینی تا ماشین اخلاقی*. تهران: مؤسسه پژوهشی مطالعات فرهنگی و اجتماعی.

References

Abdakhodaei, Z., N. Touhidi, N. Karimi, & M. Barati. 2021. *White Intelligence: From Machine Ethics to Ethical Machines*. Tehran: Institute for Cultural and Social Studies.

Bahari, Mohammadreza. 2019. *The Magic of AI* (A collection on artificial intelligence). Tehran: Institute for Cultural and Social Studies.

Bartneck, C., C. Lütge., A. Wagner., and S. Welsh. 2021. An Introduction to Ethics in Robotics and AI. In *SpringerBriefs in Ethics*. Cham: Springer Nature.

Boddington, P. 2017. *Towards a Code of Ethics for Artificial Intelligence*. 1st ed. Cham: Springer Publishing Company.

Boddington, P. 2022. *AI Ethics: Textbook (Artificial Intelligence: Foundations, Theory, and Algorithms).* Cham: Springer Publishing Company.

Coeckelbergh, M. 2020. *AI Ethics*. Cambridge, Massachusetts. USA: The MIT Press.

Ethically aligned design: A Vision for Prioritizing Human Wellbeing with Artificial Intelligence and Autonomous Systems. 2016. Retrieved from https://standards.ieee.org/wp-content/uploads/import/documents/other/ead_v2.pdf. (accessed May 5, 2024)

European Group on Ethics in Science and New Technologies. 2018. *Statement on artificial intelligence, robotics and autonomous systems*. Brussels: European Commission.

Floridi, L. 2023. *The Ethics of Artificial Intelligence- Principles, Challenges, and Opportunities.* Oxford: Oxford University Press.

_____ & J. Cowls. 2019. A Unified Framework of Five Principles for AI in Society. *Harvard Data Science Review*, 1 (1). https://doi.org/10.1162/99608f92.8cd550d1

Future of Life Institute. 2017. *Asilomar AI Principles*. https://futureoflife.org/ai-principles/ (accessed May 5, 2024)

Gordon, J. & C. B. Wrenn. 2020. Ethics of artificial intelligence. In *The Internet Encyclopedia of Philosophy*. https://iep.utm.edu/ethics-of-artificial-intelligence/. (accessed May 5, 2022).

High-Level Expert Group on Artificial Intelligence. 2019. Ethics guidelines for trustworthy AI. European Commission. https://ec.europa.eu/newsroom/dae/document.cfm?doc_id=60419 (accessed May 5, 2024)

House of Lords Select Committee on Artificial Intelligence. 2018. AI in the UK: Ready, willing and able? UK Parliament. https://publications.parliament.uk/pa/ld201719/ldselect/ldai/100/100.pdf)accessed May 5, 2024)

IEEE. 2017. Ethically aligned design: A vision for prioritizing human well-being with artificial intelligence and autonomous systems (1st ed.). https://ethicsinaction.ieee.org/ (accessed May 5, 2024)

Mazzi, F. & L. Floridi (eds.). 2023. The Ethics of Artificial Intelligence for the Sustainable Development Goals. Cham: Springer Verlag.

Müller, V. C. 2012. Autonomous Cognitive Systems in Real-World Environments: Less Control, More Flexibility and Better Interaction. *Cognitive Computation* 4 (3): 212–215.

Müller, V. C. 2020. Ethics of Artificial Intelligence and Robotics. *In The Stanford Encyclopedia of Philosophy*. https://plato.stanford.edu/archives/fall2023/entries/ethics-ai/. (accessed May 5, 2022).

Partnership on AI. 2016. Tenets. https://partnershiponai.org/tenets/ (accessed May 5, 2022)

Stahl, B., D. Schroeder, & R. Rodrigues. 2022. Ethics of Artificial Intelligence: Case Studies and Options for Addressing Ethical Challenges. cham: Springer Verlag.

Technology Assessment of Digitisation Research Team. 2018. *Policy paper on the Asilomar principles on artificial intelligence.* Berlin: Office of Technology Assessment at the German Bundestag (TAB).

UNESCO. 2021. Recommendation on the ethics of artificial intelligence. https://www.unesco.org/en/articles/recommendation-ethics-artificial-intelligence (accessed May 5, 2024)

Université de Montréal. 2018. Montreal Declaration for Responsible AI. https://www.montrealdeclaration-responsibleai.com/ (accessed May 5, 2024)

علیرضا ثقه‌الاسلامی

در سال‌های ۱۳۸۶ و ۱۳۹۲، کارشناسی ارشد و دکتری تخصصی خود را در رشته فلسفه علم از واحد علوم و تحقیقات دانشگاه آزاد اسلامی تهران دریافت کرد. وی همکاری علمی و پژوهشی خود را به‌عنوان عضو هیئت علمی پژوهشگاه علوم و فناوری اطلاعات ایران (ایرانداک) از سال ۱۳۹۴ آغاز کرد و هم‌اکنون استادیار گروه اخلاق و حقوق اطلاعات در پژوهشکده جامعه و اطلاعات این پژوهشگاه است.

فلسفه و اخلاق فناوری اطلاعات، حوزه مطالعات علم و فناوری، اخلاق پژوهش در فضای مجازی و فلسفه فناوری از جمله علایق پژوهشی وی است.