

هوشی نو

نشریه دانشجویی | انجمن هوش مصنوعی دانشگاه اراک

شماره سوم | سال اول | زمستان ۱۴۰۴





کانال ایستا هوشی نو
@Hooshino_mag

هوشی نو

استاد مشاور: دکتر مریم امیری

صاحب امتیاز: انجمن علمی هوش مصنوعی دانشگاه اراک

مدیر مسئول: محمد عرشیا فردین فر

سردبیر نشریه: محمد حسین حسینی

طراح و صفحه آرا: محمد عرشیا فردین فر

شماره نشر: شماره سوم | سال اول | زمستان ۱۴۰۴

پست الکترونیکی: Hooshinomag@gmail.com

هیئت محترم تحریریه

نویسندگان:

ستاره توکلی

فاطمه فارسبیجانی

محمد عرشیا فردین فر

ماهان عسگری تفرشی

فاطمه غیاث آبادی فراهانی

محمد انصاریپور

تیم ویراست:

محمد معین کاشفی نژاد

سبحان براتی زاده


مهلا قرینی

مهرشاد فرمهینی راهانی

سید شهاب الدین حسینی

کلیه حقوق پخش و انتشار این نشریه متعلق به

انجمن علمی هوش مصنوعی دانشگاه اراک می باشد.



به نام برنامه نویس یکتای هستی

صفحه ۴

سخن سردبیر

صفحه ۵

نورون مصنوعی چطور یاد میگیرد؟

صفحه ۱۰

نقشه راه آموزش هوش مصنوعی؛ گام دوم

صفحه ۱۵

چالش‌های ذهنی و رفتاری زبان‌های بزرگ

صفحه ۱۹

هوش مصنوعی سبز

صفحه ۲۱

نقش شبکه‌های مولد تقابلی در آینده پزشکی

صفحه ۲۵

هوش مصنوعی و تحول تجربه بازی

صفحه ۲۹

معرفی کتاب؛ Hands-On Machine Learning

صفحه ۳۱

پیش زمینه ای در رابطه با مقاله بعدی

صفحه ۳۵

انتخاب ویژگی بر اساس شاخص تمایز همسایگی

صفحه ۳۸

اخبار تازه دنیای هوش مصنوعی و تکنولوژی

صفحه ۴۴

منابع



در روزگاری که هوش مصنوعی از یک مفهوم دانشگاهی به نیرویی اثرگذار در زندگی روزمره تبدیل شده است، پرسش ما دیگر «آیا؟» نیست، بلکه «چگونه؟» است؛ چگونه می‌آموزد، چگونه تصمیم می‌گیرد و چگونه بر رفتار انسان اثر می‌گذارد. نشر سوم «هوشی‌نو» تلاشی است برای پاسخ دادن به همین پرسش‌ها با نگاهی تحلیلی و مسئولانه.

در این شماره به چالش‌های ذهنی و رفتاری مدل‌های زبانی بزرگ و کاربرد GAN‌ها در تولید داده‌های مصنوعی پزشکی پرداخته‌ایم، مقاله مطرحی در رابطه با انتخاب ویژگی بر اساس شاخص تمایز همسایگی را ترجمه کرده و اصطلاحات مطرح شده در آن را مورد بررسی قرار داده‌ایم، نقش هوش مصنوعی در بازی‌سازی را واکاوی کرده‌ایم و به بخش بعدی مقاله جذاب «یادگیری نوروون مصنوعی» رسیدیم. همچنین در مرحله‌ی دوم نقشه راه یادگیری هوش مصنوعی و معرفی کتاب، کوشیده‌ایم مسیر روشن‌تری پیش روی علاقه‌مندان این حوزه ترسیم کنیم.


امیدواریم که این نشر، گامی هرچند کوچک در جهت فهم عمیق‌تر و استفاده آگاهانه‌تر از هوش مصنوعی باشد؛ فهمی که مقدمه‌ی ساختن آینده‌ای مسئولانه‌تر با فناوری است.

با احترام،
محمدحسین حسنی

”

نویسنده: محمد عرشیا فردین فر

برای ساده کردن مسئله، بایاس را صفر و تابع فعال ساز را خطی در نظر می‌گیریم. در این صورت شکل ۲ به صورت زیر خلاصه خواهد شد:

شکل ۲: ساختار نورون مصنوعی ساده شده با $b=0$

خب در اینجا نورون باید پارامتر w و b را طوری محاسبه می‌کرد که خروجی y_p (خروجی پیش‌بینی شده توسط نورون) با خروجی y_t (خروجی مطلوب) یکسان شود. یا اگر نتوانست یکسان شود، حداقل به y_t نزدیک باشد! ما در جلسه قبل داشتیم:

$$y_p = w * x + b$$

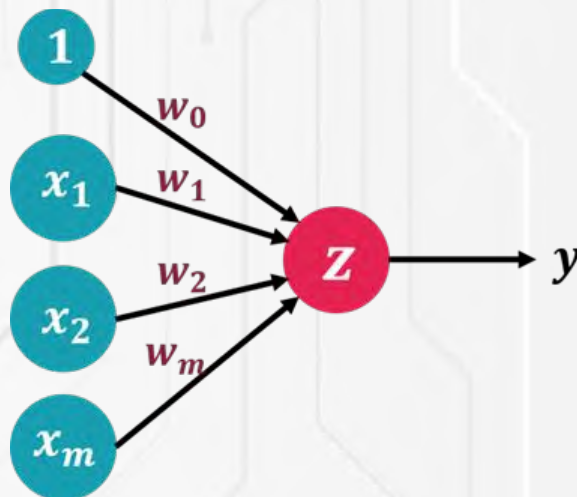
گفتیم برای شروع باید یک مقدار اولیه^۱ به پارامترها اختصاص دهیم. بایاس را صفر گذاشتیم، w را هم برابر با یک قرار می‌دهیم. به این کار مقداردهی اولیه گفته می‌شود. در این صورت برای $w=1$ و $b=0$ مقدار y_p به صورت زیر محاسبه خواهد شد:

X	۲	۳	۴	۵	۶	۷	۸
Y_t	۴	۶	۸	۱۰	۱۲	۱۴	۱۶
Y_p	۲	۳	۴	۵	۶	۷	۸

ما مقادیر را محاسبه کردیم و در ستون y_p از جدول بالا قرار دادیم. الان چه کار کنیم؟ صرفاً با فرمولی که داشتیم Y تا ورودی دادیم و Y تا خروجی گرفتیم. حالا چطور قرار است یک نورون از این اعداد چیزی یاد بگیرد؟ آیا می‌توان با مقایسه y_p و y_t به نتیجه‌ای رسید؟ یعنی ما ببینیم که y_p چقدر از y_t دور است، آنگاه بر اساس این فاصله وزن‌ها را تغییر بدهیم تا به خروجی مطلوب برسیم. به نظرتان این گفته منطقی است؟

یادآوری ساختار نورون مصنوعی

در نشر قبل هوشی‌نو با ساختار یک نورون مصنوعی آشنا شدیم. گفتیم که یک نورون مصنوعی ورودی‌ها را دریافت کرده و به صورت وزن‌دار با هم جمع می‌کند. سپس نتیجه را از یک تابع فعال‌ساز عبور می‌دهد. در شکل زیر ساختار نورون مصنوعی که معرفی کردیم آورده شده است:



شکل ۱: ساختار نورون مصنوعی

حالا بیایید با یک مثال نحوه یادگیری نورون مصنوعی را مرور کنیم. فرض کنید داده‌های زیر به ما داده شده است:

X	۲	۳	۴	۵	۶	۷	۸
Y_t	۴	۶	۸	۱۰	۱۲	۱۴	۱۶

همان‌طور که مشاهده می‌کنید نمونه‌ها اعدادی از ۲ تا ۸ هستند. برچسب‌ها یا labelها هم اعداد ۴، ۶، ۸، ... و ۱۶ هستند. خوب هدف ما چیست؟ هدف، یادگیری نورون مصنوعی است؛ یعنی نورون بتواند خروجی‌های موردنظرمان یعنی اعداد ۴، ۶ و ... را تولید کند. ما اینجا یک ورودی و یک خروجی داریم. شاید برایتان سوال باشد که چرا یک ورودی، در صورتی که ما Y تا X داریم؟ در جواب باید بگوییم که ما Y نمونه داریم نه Y ورودی. در اینجا، ما یک ورودی و یک خروجی داریم. مثلاً نمونه ۲ منجر به خروجی ۴ شده است، یا نمونه ۷ منجر به خروجی ۱۴ شده است.

نکته: برچسب در شبکه عصبی یعنی چه؟

برچسب به معنای مقدار مطلوب است. یعنی مقدار درستی که ما می‌خواهیم نورون بتواند آن را تخمین بزند.

توابع اتلاف انواع مختلفی دارند. ما در این نشر تنها یک تابع اتلاف را معرفی می‌کنیم چون می‌خواهیم به صورت کلی با فرآیند آموزش شبکه عصبی آشنا شوید. در نشریات آینده به صورت جداگانه انواع توابع اتلاف را بررسی خواهیم کرد.

یکی از ساده‌ترین توابع اتلاف در شبکه عصبی، تابع MSE یا Mean Squared Error یا میانگین مربعات خطا است. فرمولی که برای MSE وجود دارد به شکل زیر است:

$$MSE \text{ loss} = \frac{1}{N} \sum_{i=1}^N (y_p - y_t)^2$$

معادله ۱

همان‌طور که مشاهده می‌کنید خروجی مطلوب یعنی y_t از خروجی شبکه یعنی y_p کم شده سپس به توان ۲ رسانده شده است. به ازای هر نمونه، یک خروجی (y_p) داریم. و به ازای هر خروجی، یک خطا خواهیم داشت. سپس مقدار خطای همه نمونه‌ها با هم جمع شده و خطای میانگین شبکه محاسبه شده است. به این ترتیب ما درکی نسبی از عملکرد شبکه خواهیم داشت. به این شکل که هرچه قدر خطا کمتر باشد، احتمالاً عملکرد شبکه بهتر است و هرچه قدر خطا بیشتر باشد، شبکه عملکرد خوبی نخواهد داشت.

گفتیم MSE یک از ساده‌ترین توابع اتلاف است. توابع اتلاف دیگری نیز وجود دارند که بسته به مسئله می‌توانیم از آن‌ها استفاده کنیم. چند تابع اتلاف رایج عبارت‌اند از:

- میانگین مربعات خطا (MSE)
- میانگین قدرمطلق خطا (MAE)
- میانگین جذر مربعات خطا (RMSE)
- تابع اتلاف Hinge
- تابع اتلاف Binary Cross Entropy
- تابع اتلاف Multi Cross Entropy
- تابع اتلاف Triplet
- و ...

نکته:

در yp ، حرف p مخفف کلمه predicted یعنی پیش‌بینی شده و در yt حرف t مخفف کلمه target یعنی هدف است.

تابع اتلاف یا تابع هزینه یا تابع هدف در شبکه عصبی

احتمالاً با سنسور دنده عقب اتومبیل آشنا هستید. این سنسور فاصله عقب ماشین را از مانع‌های پشت ماشین می‌سنجد. سپس نتیجه را با بوق زدن به ما می‌فهماند. اگر مانعی پشت ماشین نباشد، اصلاً بوق نمی‌زند. اگر به مانعی نزدیک شویم شروع به بوق زدن متناوب می‌کند و اگر دیگر خیلی به مانع نزدیک شویم تبدیل به بوق ممتد خواهد شد! در واقع سنسور دنده عقب فاصله میان اتومبیل ما و مانع را به بوق ممتد تبدیل می‌کند. بر اساس فاصله بین بوق‌ها به ما می‌گوید که چقدر با مانع فاصله داریم. شاید سنسور دنده عقب اتومبیل را بتوان یک نوع تابع اتلاف محسوب کرد!



شکل ۳: سنسور دنده عقب خودرو

در شبکه عصبی برای محاسبه میزان فاصله میان خروجی پیش‌بینی شده توسط شبکه و خروجی مطلوب، از تابع اتلاف استفاده می‌شود. در بخش قبلی گفتیم که ما نیاز داریم بدانیم که خروجی پیش‌بینی شده یعنی y_p چقدر از خروجی مطلوب یعنی y_t دور هستند. یکی از راه‌حل‌ها استفاده از تابع اتلاف است. تابع اتلاف، مقدار خروجی شبکه و مقدار خروجی مطلوب را دریافت کرده و فاصله میان آن دو را حساب می‌کند. به خروجی تابع اتلاف، خطا یا «Error» گفته می‌شود. ایده‌آل ما این است که خطا صفر باشد. حالا ممکن است هیچ‌وقت این خطا صفر نشود! اما هرچه قدر به صفر نزدیک‌تر باشد، یعنی خروجی شبکه به خروجی مطلوب ما نزدیک‌تر است.

در نتیجه لزومی ندارد که با یکبار تغییر وزن‌ها به جواب برسیم. در مسائل پیچیده ممکن است فرایند بهینه‌سازی هزاران بار تکرار شود و در نهایت، به یک خطای قابل قبول برسد، نه خطای صفر! به بیان ریاضی در شبکه عصبی ما انتظار داریم:

$$w(\tau+1) = w(\tau) + \Delta w(\tau)$$

معادله ۲

که در آن $w(\tau)$ مقدار وزن در iteration یا تکرار τ ام، $w(\tau+1)$ مقدار وزن‌ها در تکرار $(\tau+1)$ ام و $\Delta w(\tau)$ مقدار تغییر وزن‌ها در یک تکرار است. معادله ۲ می‌گوید در تکرار جدید، می‌خواهم وزن‌ها را به اندازه $\Delta w(\tau)$ تغییر دهم. نکته اینجاست که همانند مثال ماشین که با افزایش صدای بوق، سرعت ما کم می‌شد، اینجا هم $\Delta w(\tau)$ به مرور با کاهش اتلاف کوچکتر می‌شود. دقت کنید $\Delta w(\tau)$ تابعی از τ است، یعنی تابعی از زمان یا تکرار است. یعنی به مرور زمان تغییر می‌کند. الگوریتم‌های بهینه‌سازی متعددی وجود دارند. چند الگوریتم بهینه‌سازی در شبکه عصبی عبارتند از:

- گرادیان کاهشی (Gradient Decent)
- گرادیان کاهشی با مومنتوم (Gradient Decent with Momentum)
- Adagrad
- RMSprop
- Adam
- ... ۹

گرادیان کاهشی

الگوریتم گرادیان کاهشی ساده‌ترین رویکرد را در استفاده از گرادیان برای بروزرسانی وزن‌ها ارائه می‌دهد. رابطه ریاضی برای این بهینه‌ساز به شکل زیر است:

$$w(\tau+1) = w(\tau) - \eta \nabla E(w(\tau))$$

معادله ۳

که در آن η نرخ یادگیری و $E(w(\tau))$ خطا در iteration یا تکرار τ است. همان‌طور که مشاهده می‌کنید، گرادیان خطا در تکرار τ محاسبه شده و در η ضرب می‌شود و نتیجه در -1 ضرب خواهد شد.

برگردیم به مثالی که داشتیم. اگر بخواهیم خطای MSE را برای شبکه خودمان محاسبه کنیم، باید بنویسیم:

X	۲	۳	۴	۵	۶	۷	۸
Y_t	۴	۶	۸	۱۰	۱۲	۱۴	۱۶
Y_p	۲	۳	۴	۵	۶	۷	۸


$$MSE = \frac{1}{7}((2-4)^2 + (3-6)^2 + (4-8)^2 + (5-10)^2 + (6-12)^2 + (7-14)^2 + (8-16)^2) = \frac{203}{7} = 29$$

خب می‌بینید شبکه تک نورونی ما خطای MSE برابر با ۲۹ دارد. خطای زیادی است و تا صفر فاصله خیلی زیادی وجود دارد. چطور این فاصله باید کم شود؟ سنسور دنده عقب را در نظر بگیرید. زمانی که بوق نمی‌زند ما با فشار بیشتری پدال گاز را فشار می‌دهیم، اما زمانی که شروع به بوق زدن می‌کند پایمان را کمی از پدال گاز برمی‌داریم تا سرعت کم شود. در نهایت اگر بوق ممتد بشنویم، سریعاً خودرو را متوقف می‌کنیم. در اینجا هم ما به دنبال چنین چیزی هستیم. یعنی می‌خواهیم نورون، وزن‌ها را طوری تغییر دهد که خطا به سمت صفر رود. اگر فاصله تا صفر زیاد باشد با سرعت بیشتری وزن‌ها را تغییر دهد. اگر هم فاصله تا صفر کم باشد سرعت تغییر وزن‌ها را کم کند. در نهایت آنقدر وزن‌ها را تغییر دهد که به مقصد یعنی خطای صفر برسیم. در شبکه عصبی این کار بر عهده بهینه‌ساز^۱ است. در بخش بعدی با مفهوم بهینه‌سازی آشنا خواهیم شد.


الگوریتم‌های بهینه‌سازی در شبکه عصبی

بهینه‌سازی یک تابع در ریاضیات، معمولاً به این معنا است که پارامترهای تابع مورد نظرمان را طوری انتخاب کنیم که آن تابع مینیمم یا ماکزیمم شود. در بخش قبل گفتیم هدفمان این است که وزن‌های شبکه را طوری تغییر دهیم که خروجی تابع اتلاف صفر شود. پس یک الگوریتم بهینه‌سازی می‌تواند هدف ما را برآورده سازد. یک الگوریتم بهینه‌سازی به صورت تکراری انجام می‌شود تا یک راه‌حل بهینه حاصل شود. یعنی در شبکه عصبی ما به الگوریتمی نیاز داریم که وزن‌ها را آنقدر تغییر دهد تا به کمترین اتلاف برسیم.


اگر مقدار نرخ یادگیری خیلی بزرگ انتخاب شود، نباید انتظار داشت که الگوریتم بهینه‌سازی حتی همگرا شود! چون وزن‌ها همیشه در حال پرش هستند. یعنی اتفاقی مشابه با تصویر زیر خواهد افتاد. مشاهده می‌کنید که اتلاف نه تنها کم نشده، بلکه افزایش هم یافته است.



اگر هم نرخ یادگیری خیلی کوچک انتخاب شود، فرایند آموزش شبکه بسیار طولانی خواهد شد. مثلاً شبکه‌ای که با نرخ یادگیری مناسب یک ساعت آموزش طول می‌کشد، در این حالت شاید یک روز کامل طول بکشد و باز هم به نتیجه موردنظرمان نرسد. در نمودار ۳، تأثیر مقدار نرخ یادگیری بر آموزش شبکه نشان داده شده است. در این نمودار مشاهده می‌کنید که انتخاب نرخ یادگیری باید متناسب با مسئله باشد. این مقدار مناسب، بسته به کاربردهای مختلف متفاوت است و معمولاً به صورت تجربی تعیین می‌شود.



به شکل ۴ نگاه کنید؛ چون ما می‌خواهیم مقدار خطا مینیمم شود باید در خلاف جهت گرادیان حرکت کنیم تا به نقطه مینیمم برسیم. الگوریتم گرادیان کاهشی می‌گوید با استفاده از وزن اولیه گرادیان خطا را محاسبه کن. سپس گرادیان خطا را در نرخ یادگیری ضرب کرده و مقدار به دست آمده را از وزن‌های فعلی کم کن. در این نقطه، تکرار اول تمام شده و وارد تکرار دوم می‌شویم. در تکرار دوم، گرادیان خطا را با وزن‌های جدید محاسبه کرده و در نرخ یادگیری ضرب می‌کنیم. سپس مقدار به دست آمده را از وزن‌ها کم می‌کنیم. به همین ترتیب این فرایند را تا آنجا ادامه می‌دهیم که خطا مینیمم شود. در شکل زیر این فرایند به صورت فرضی نشان داده شده است.



نرخ یادگیری در شبکه عصبی چیست؟

نرخ یادگیری^۲ در شبکه عصبی، ضریبی است که به وسیله آن می‌توان مقدار تغییر وزن‌ها را تنظیم کرد. یعنی اگر نرخ یادگیری بزرگ انتخاب شود، با گام‌های بلندتری به سمت مینیمم حرکت خواهیم کرد. اما اگر کوچک باشد، با گام‌های کوچک‌تری به سمت مینیمم حرکت خواهیم کرد. شاید پیش خودتان بگویید که اگر اینطور است، چه لزومی دارد که نرخ یادگیری کوچک انتخاب شود. خب آن را مقداری بزرگ بگذاریم تا زودتر به نقطه مینیمم برسیم، اما موضوع به این سادگی‌ها هم نیست. آیا در هنگام دنده عقب، بدون کاهش سرعت با وجود بوق هشدار همان‌طور به مسیرمان ادامه می‌دهیم؟!

مثال عددی آموزش نورون

بیاید در مثالی که مشغول حل آن بودیم مطالبی که در بخش قبل یاد گرفتیم را اعمال کنیم. یعنی وزن را با استفاده از گرادیان کاهش تغییر دهیم. با توجه به معادله ۳، برای تغییر وزن‌ها نیاز است ابتدا گرادیان اتلاف را محاسبه کنیم. اگر یادتان باشد ما از تابع اتلاف MSE استفاده کردیم. حالا با توجه به معادله ۳، باید از این تابع اتلاف نسبت به وزن‌ها مشتق بگیریم:

$$\frac{\partial J}{\partial w} = \frac{1}{n} \sum_{i=1}^n 2 \frac{\partial y_p^i}{\partial w} (y_p^i - y_r^i)$$

$$y_p = xw + b = xw$$

$$\frac{\partial J}{\partial w} = \frac{1}{n} \sum_{i=1}^n 2x^i (y_p^i - y_r^i)$$

معادله ۴

دقت کنید که ما برای ساده شدن مسئله، بایاس را صفر در نظر گرفتیم. نرخ یادگیری را نیز برابر با ۰.۰۱ در نظر می‌گیریم و شروع به حل مسئله می‌کنیم. در اولین تکرار داریم:

$$\frac{\partial J}{\partial w} = \frac{2}{7} (2 * (2 - 4) + 3 * (3 - 6) + 4 * (4 - 8) + 5 * (5 - 10) + 6 * (6 - 12) + 7 * (7 - 14) + 8 * (8 - 16)) = -58$$


$$w = w - 0.01 * (-58) = 1.58$$

این فرایند را همچنان ادامه می‌دهیم تا زمانی که به نتیجه مطلوب برسیم:

iter	۱	۲	۳	۴	۵	۶	۷	۸	۹	
w	۱	۱.۵۸	۱.۸۲۳	۱.۹۲۵	۱.۹۶۸	۱.۹۸۶	۱.۹۹۴	۱.۹۹۷	۱.۹۹۹	...
L	۲۹	۵.۱۱	۰.۹۰۲	۰.۱۵۹	۰.۰۲۸	۰.۰۰۴	۰.۰۰۸	۰.۰۰۰۱۵	۰.۰۰۰۰۲	...
$\frac{\partial J}{\partial w}$	-۵۸	-۲۴.۳	-۱۰.۲۳	-۴.۲۹	-۱.۸۰	۰.۷۵	۰.۳۱	۰.۱۳	۰.۰۵	

مشاهده می‌کنید هر قدمی که پیش می‌رویم، مقدار

اتلاف کم و کمتر شده و به عدد صفر نزدیک‌تر می‌شود. وزن تقریباً ۲ به دست آمد. احتمالاً خیلی از شما از اول می‌دانستید که وزن چه باید باشد، اما با حل این مثال متوجه شدید که یک نورون ساده چه محاسباتی می‌کند تا بفهمد وزن درست چه است؛ یعنی فرایند یادگیری نورون مصنوعی را از صفر تا صد خودتان محاسبه کردید. اگر نمودار اتلاف را رسم کنیم خواهیم داشت:



تکرار

نمودار ۴: نمودار اتلاف

حالا نورون ما آموزش دیده است. مقدار w برابر با ۱.۹۹۹ بدست آمد. حالا نورون ما می‌تواند با وزن جدیدی که دارد، پیش‌بینی‌های درستی انجام دهد. مثلاً الان اگر به نورون ورودی ۹ را بدهیم انتظار داریم خروجی ۱۸ بدهد. درست است؟ ببینیم نورون چه تخمینی می‌زند:

$$y_p = w * x + b = 1.999 * 9 + 0 = 17.991$$

مشاهده می‌کنید که تقریباً نتیجه را درست حدس زده است. اگر بخواهیم دقیقاً ۱۸ را تخمین بزنند چکار باید بکنیم؟ باید فرایند بهینه سازی را انقدر ادامه دهیم تا یادگیری نورون مصنوعی، کامل‌تر شده و وزن به عدد ۲ نزدیک‌تر شود.

در نشر بعد با شبکه عصبی MLP یا پرسپترون چندلایه که یکی از ساده‌ترین شبکه‌های عصبی است آشنا می‌شویم. به تشریح این شبکه پرداخته و نحوه آموزش دیدن این شبکه با استفاده از الگوریتم پس انتشار خطا^۱ را با یک مثال عددی دیگر به شما دوستاناران هوش مصنوعی آموزش خواهیم داد. پس نشر شماره چهارم هوشی نو را از دست ندهید [۱]!

۳

مبانی هوش مصنوعی و یادگیری ماشین

- هوش مصنوعی چیست؟ یادگیری ماشین چیست؟
- یادگیری نظارت شده (Supervised) در مقابل یادگیری بدون نظارت (Unsupervised)
- الگوریتم‌های کلیدی: رگرسیون خطی، درخت تصمیم، الگوریتم k-nearest neighbors
- بیش‌برازش (Overfitting) و کم‌برازش (Underfitting)
- معیارهای ارزیابی (دقت، صحت، بازیابی، امتیاز F)

۴

ریاضیات برای هوش مصنوعی و یادگیری ماشین

- جبر خطی
- حساب دیفرانسیل
- آمار و احتمال
- تکنیک‌های بهینه‌سازی

۱

مبانی برنامه‌نویسی

- متغیرها و انواع داده
- ساختارهای کنترلی
- توابع و ماژول‌ها
- برنامه‌نویسی شی‌گرا
- ساختارهای داده‌ای پایه

۴

یادگیری عمیق

- شبکه‌های عصبی و روش پس‌انتشار
- معماری‌های یادگیری عمیق
- آموزش شبکه‌های عمیق
- یادگیری انتقالی
- فریم‌ورک‌ها

۵

یادگیری ماشین

- الگوریتم‌های پیشرفته
- یادگیری تجمعی
- ارزیابی و اعتبارسنجی مدل
- تنظیم ابرپارامترها
- آشنایی با فریم‌ورک‌های یادگیری ماشین

۴

مهارت‌های داده برای هوش مصنوعی و یادگیری ماشین

- جمع‌آوری و پاک‌سازی داده
- تحلیل کاوشگرانه داده‌ها
- مهندسی ویژگی‌ها
- مصورسازی داده‌ها

۹

یادگیری تقویتی Reinforcement Learning

- فرایندهای تصمیم‌گیری مارکوف
- الگوریتم‌های Deep Q-Learning و Q-Networks
- روش‌های گرادینان سیاست
- کاربردها در هوش مصنوعی بازی‌ها، رباتیک و غیره

۱۱

پردازش زبان طبیعی

- پیش‌پردازش متن
- عقیده کای
- شناسایی موجودیت‌های نامدار
- مدل‌های زبانی
- چت‌بات‌ها و هوش مصنوعی مکالمه‌ای

۱۱

بینایی ماشین

- پیش‌پردازش تصویر
- شبکه‌های عصبی پیچشی
- شناسایی و بخش‌بندی اشیاء
- تولید تصویر
- کاربردها در سلامت، خودرو و غیره

۱۱

ساخت برنامه‌های هوش مصنوعی و یادگیری ماشین

- پروژه‌های End-to-end یادگیری ماشین
- استقرار مدل‌ها
- نظارت و نگهدار از مدل‌ها

۱۰

ابزارها و کتابخانه‌ها

- Jupyter Notebooks
- Scikit-learn
- TensorFlow and Keras
- PyTorch
- Pandas and Numpy



آموزش گام دوم


یادآوری ساختار نورون مصنوعی

در ادامه نقشه راه به مباحث ریاضی می‌رسیم. در زمان روند یادگیری ریاضیات پایه در هوش مصنوعی همچنان به برنامه‌نویسی با زبان انتخابی خود ادامه دهید تا آن را فراموش نکنید. در ادامه با یکی از مسئله‌های هوش مصنوعی آشنا شده و روش حل آن را همراه کاربرد ریاضیات در این مسئله می‌بینیم. موارد کاربردی که در مسئله مشخص است را از زاویه هر مبحث در ریاضیات بررسی می‌کنیم و بقیه مواردی که باید مورد مطالعه قرار بگیرد را خواهیم گفت.

یکی از مسئله‌های حل شده توسط هوش مصنوعی و شبکه عصبی، مسئله «خانه‌های شهر بوستون» است. در این مسئله برای هر خانه یک قیمت و تعداد پارامتر (ویژگی) مانند مساحت، تعداد اتاق‌ها، فاصله از مکان‌های متفاوت و... که در مجموع شامل ۱۴ پارامتر با ملاک‌های اندازه‌گیری متفاوت برای هر کدام از این پارامترها است، را خواهیم دید (مثلاً تعداد اتاق‌ها یک کمیت گسسته است، واحد اندازه‌گیری مساحت فوت مربع است). این مسئله با مدل هوش مصنوعی رگرسیون خطی حل شده است. برای اینکه به صورت مفهومی‌تر کاربرد هر کدام از مباحث را در هوش مصنوعی ببینیم، ابتدا به نمای ظاهری شبکه عصبی نگاه می‌اندازیم.

در شبکه عصبی کاملاً متصل هر نورون (نودهای داخل گراف) می‌تواند از تمام نورون‌های لایه قبل خروجی بگیرد و بعد از انجام عملیات‌های خود خروجی را به تمام نورون‌های لایه بعد ارسال کند. در ستون سمت چپ، یعنی لایه ورودی، به تعداد پارامترهای مسئله نورون برای گرفتن ورودی مسئله داریم، سپس لایه‌هایی در میانه کار قرار می‌گیرند؛ که معمولاً ابتدا تعداد نورون‌ها در هر لایه زیاد می‌شود و بعد از چند لایه، تعداد نورون‌ها شروع به کاهش می‌کند، سپس در سمت راست ترین لایه که با نقطه‌های نارنجی مشخص شده است، به تعداد مورد نیاز نورون خروجی داریم.


ما از رگرسیون خطی برای مسئله مورد بحث استفاده می‌کنیم که با توجه به نوع خروجی مدنظر برای مسئله که یک داده عددی است انتخاب شده. پس فقط به یک خروجی و ۱۴ عدد ورودی نیاز داریم. نود خروجی نشان دهنده قیمت پیش‌بینی شده توسط مدل است که در طول پروسه آموزش قرار است به کمترین خطا برسد. حال بیاید موارد متفاوت را در این مسئله مورد بحث قرار دهیم.



نمودار ۱: مثال رگرسیون خطی (Linear regression)

جبر خطی:

در جبر خطی ما به بررسی مسئله‌ها با بعدهای متفاوت و حل آن‌ها، به دست آوردن بردارهای خطی مستقل و وابسته، بردار ویژه، مقدار ویژه و کار با ماتریس‌ها می‌پردازیم. در پروسه آموزش شبکه عصبی در ابتدا کل یال‌ها با اعداد تصادفی پر می‌شوند.



شکل ۱: نمونه گراف یک شبکه عصبی کاملاً متصل^۱

در گراف بالا هر کدام از نودها به تمام نودها (گره‌ها) در ستون (لایه) قبل و بعد از خودش متصل است که تشکیل یک شبکه عصبی کاملاً متصل را می‌دهد.

آمار و احتمال:

در مسئله پیش‌بینی قیمت خانه، ما با داده‌هایی سروکار داریم که ذاتاً همراه با عدم قطعیت و خطای تصادفی (نویز) هستند. آمار و احتمال، ابزارهایی به ما می‌دهد تا این عدم قطعیت را مدل‌سازی کنیم. مثلاً در رگرسیون خطی فرض می‌کنیم قیمت واقعی خانه به صورت ترکیبی خطی از ویژگی‌ها به علاوه یک نویز است که معمولاً توزیع نرمال با میانگین صفر در نظر گرفته می‌شود. این فرض باعث می‌شود که بتوانیم از روش‌های آماری مثل «برآورد درست‌نمایی بیشینه» استفاده کنیم؛ یعنی ضرایب اوزان مدل، طوری انتخاب شوند که احتمال مشاهده داده‌ها بیشینه شود.

علاوه بر این، مفاهیمی مثل واریانس و کوواریانس به ما کمک می‌کنند بفهمیم هر ویژگی چه قدر روی قیمت اثر دارد و ویژگی‌ها چه قدر با هم هم‌بسته یا وابسته (نزدیک یا دور بودن اطلاعات نسبت به هم) هستند. اگر دو ویژگی خیلی به هم وابسته باشند (مثلاً مساحت خانه و تعداد اتاق‌ها)، این وابستگی در مدل‌سازی باید مدیریت شود. در نهایت، آمار و احتمال به ما امکان می‌دهد پیش‌بینی‌ها را نه فقط به صورت یک عدد قطعی، بلکه همراه با یک میزان عدم قطعیت یا فاصله‌ی اطمینان بیان کنیم.

بهینه‌سازی:

بهینه‌سازی همان بخش اصلی یادگیری است؛ جایی که مدل وزن‌ها و پارامترهای خود را طوری تغییر می‌دهد که خطا کمینه شود. در رگرسیون خطی ساده می‌توان جواب بهینه را با یک فرمول تحلیلی (معادله نرمال) به دست آورد، چون مسئله محدب است و فقط یک جواب دارد. اما در شبکه‌های عصبی به خاطر وجود لایه‌های غیرخطی و تعداد زیاد پارامترها، معمولاً جواب تحلیلی وجود ندارد. به همین دلیل از الگوریتم‌های تکراری مثل «گرادیان کاهشی» و انواع پیشرفته‌تر آن (SGD، Adam، RMSProp) استفاده می‌کنیم.

در این روش‌ها، در هر مرحله مقدار گرادیان (مشتق تابع اتلاف نسبت به وزن‌ها) محاسبه می‌شود و وزن‌ها کمی در جهت عکس گرادیان تغییر می‌کنند تا خطا کاهش پیدا کند. این فرایند در هر اپیاک، تکرار می‌شود تا جایی که مدل به یک نقطه پایدار برسد. نکته مهم در بهینه‌سازی، انتخاب نرخ یادگیری (learning rate) است؛ اگر خیلی بزرگ باشد مدل نوسان می‌کند و به جواب خوبی نمی‌رسد، و اگر خیلی کوچک باشد فرآیند یادگیری خیلی کند پیش می‌رود.

سپس با استفاده از ضرب ماتریس‌ها مقداری محاسبه می‌شود؛ تفاوت بین جواب مدل و قیمت خانه، برای اندازه‌گیری مقدار خطا به «تابع اتلاف» ارسال می‌شود. در برگشت خطا برای اصلاح مقدار وزن هر یال، از مشتق گیری برداری-ماتریسی استفاده می‌شود تا مقدار تغییر برای هر وزن مشخص شود. این عملیات در طول فرایند یادگیری و در هر اپیاک (Epoch) یا همان چرخه تمرین مدل انجام می‌شود.


اما غیر از موارد بالا که در خود مدل و زمان تمرین دادن مدل کاربرد دارد، جبر خطی با مفهومی به نام کاهش بُعد (ترکیب ویژگی‌های هم‌بسته و کاهش ورودی‌های مسئله) تعداد ورودی‌ها را برای مدل کاهش می‌دهد. به این معنا که در این مسئله اگر باید ۱۴ ویژگی به مدل بدهیم؛ ولی دو ویژگی داشته باشیم که بتوان با یک عملیات یکی را از روی دیگری محاسبه کرد، یکی از این دو ویژگی اضافی است و کاربردی در آموزش مدل ما ندارد. جبر خطی با بررسی داده‌ها می‌تواند تعیین کند که آیا می‌توان دو داده مرتبط (به عنوان مثال تعداد اتاق‌های خانه که تا حد زیادی با مساحت خانه در ارتباط است) پیدا کرد یا نه، اگر بتوان داده‌های مرتبط را پیدا کرد تعداد پارامترها در مدل کاهش می‌یابد و در نتیجه مدل بهینه‌تر آموزش می‌بیند.

حساب دیفرانسیل (و انتگرال):

از حساب دیفرانسیل در محاسبات بیشترین استفاده را می‌کنیم. این مبحث برای اثبات قضایا و محاسبات عددی لازم در زمان آموزش مدل استفاده می‌شود. همچنین مشتق و گرادیان نیز از جمله موارد پر استفاده در زمان «اصلاح وزن‌ها» یا Backpropagation (که با آن در نشر بعدی هوشی‌نو آشنا خواهید شد) است که مقدار اصلاح هر وزن را با توجه به فرمول و با استفاده از قاعده زنجیره مشتق‌ها به دست می‌آوریم.


انتگرال‌ها نیز در یادگیری ماشین و آمار نقش دارند، به ویژه در محاسبات احتمالاتی (مثلاً محاسبه مساحت زیر منحنی «توزیع نرمال» یا محاسبه «امید ریاضی» متغیرهای تصادفی). در بخش بهینه‌سازی هم از حساب دیفرانسیل استفاده می‌کنیم. الگوریتم «گرادیان کاهشی» که اساس آموزش مدل‌های یادگیری ماشین است، بر پایه محاسبه گرادیان‌ها و تغییر وزن یال‌ها در جهت کاهش مقدار خطای بازگشتی از تابع اتلاف بنا شده است.

- حساب دیفرانسیل، کتاب «Calculus for Machine Learning Understanding the Language of Mathematics» اثر «Jason Brownlee Founder»



تصویر ۲: کتاب Calculus for Machine Learning

- کتاب «Probability for Statistics and Machine Learning» از «Anirban DasGupta» نیز برای آمار و احتمال پیشنهاد می‌شود.



تصویر ۳: کتاب Probability for Statistics and Machine Learning


در این روش‌ها، در هر مرحله مقدار گرادیان (مشتق تابع اتلاف نسبت به وزن‌ها) محاسبه می‌شود و وزن‌ها کمی در جهت عکس گرادیان تغییر می‌کنند تا خطا کاهش پیدا کند. این فرایند در هر ایپاک یا چرخه تمرین مدل، تکرار می‌شود تا جایی که مدل به یک نقطه پایدار برسد. نکته مهم در بهینه‌سازی، انتخاب نرخ یادگیری (learning rate) است؛ اگر خیلی بزرگ باشد مدل نوسان می‌کند و به جواب خوبی نمی‌رسد، و اگر خیلی کوچک باشد فرآیند یادگیری خیلی کند پیش می‌رود.

به مواردی مانند تابع اتلاف و نرخ یادگیری در بخش یادگیری نورون مصنوعی همین نشر پرداختیم و می‌توانید برای جزئیات بیشتر به مقاله «نورون مصنوعی چطور یاد می‌گیرد؟» مراجعه کنید.

منابع مفید یادگیری


و اما بحث مهم در این قسمت، مبحث معرفی کتاب است که به آن می‌پردازیم. در دانشگاه‌های مختلف ممکن است منابع دیگری تدریس شوند، اما سعی ما بر این بود که کتاب‌ها مرتبط با مباحث یادگیری ماشین و هوش مصنوعی باشند.

- مبحث جبر خطی، کتاب «Linear Algebra and Optimization for Machine Learning» به نویسندگی «Charu C. Aggarwal»



تصویر ۱: کتاب Linear Algebra and Optimization for Machine Learning

• برای بحث بهینه‌سازی نیز می‌توانید کتاب اول را بخوانید یا از کتاب «Optimization for Machine Learning» اثر «Stephen Suvrit Sra, Sebastian Nowozin» و «J. Wright» استفاده کنید که وابسته به تصمیم شماست.



تصویر ۴: کتاب Optimization for Machine Learning

گام دوم از نقشه راه یادگیری هوش مصنوعی هوشی‌نو نیز به پایان رسید، در این گام آموختیم به این نیاز داریم که با پایه‌های قوی به مراحل و پله‌های بالاتر مبحث هوش مصنوعی صعود کنیم، در این راستا باید ریاضیات را جدی بگیریم تا از پشت پرده و نحوه کارکرد بسیاری از کتابخانه‌های توسعه هوش مصنوعی مانند «Pytorch» و «TensorFlow» آشنا شویم.

در نشر بعد نشریه دانشجویی هوشی‌نو، به گام سوم نقشه راه آموزش هوش مصنوعی می‌پردازیم و با مباحث تخصصی‌تر مبانی هوش مصنوعی و یادگیری ماشین آشنا می‌شویم.

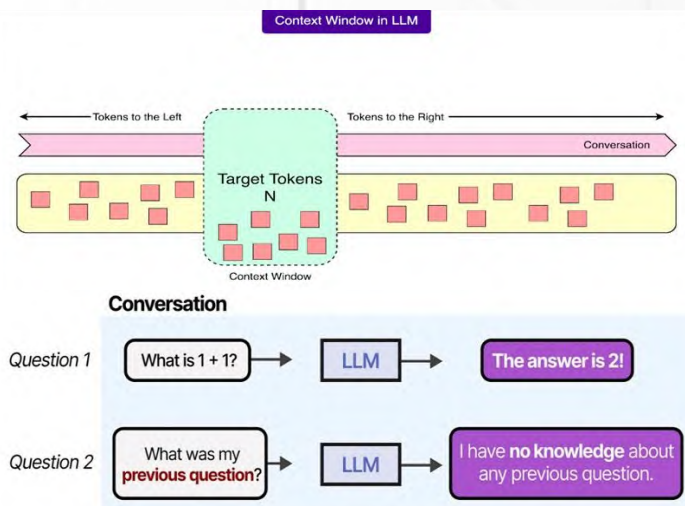
بخش محدودی از ورودی‌های اخیر خود هستند. این محدودیت باعث می‌شود که با افزایش طول ورودی، مدل نتواند تمام جزئیات متن طولانی را حفظ کند و به مشکلاتی مانند:

- فراموش شدن بخش‌های ابتدایی متن
- بروز ناهماهنگی معنایی در متن تولیدشده
- تمرکز بیش از حد بر انتهای ورودی

این محدودیت‌ها می‌توانند به اختلال در تولید متن دقیق و مرتبط منجر شوند، به‌ویژه زمانی که مدل باید اطلاعات زیادی را پردازش کند. به‌عنوان مثال، وقتی از مدل خواسته می‌شود که خلاصه‌ای از یک مقاله بلند یا یک داستان پیچیده ارائه دهد، ممکن است تنها بر بخش‌های انتهایی یا جزئیات کم‌اهمیت‌تر تمرکز کند، درحالی‌که بخش‌های کلیدی و ابتدایی متن که برای درک موضوع ضروری هستند، نادیده گرفته شوند [۳].

برای حل مشکل محدودیت حافظه، پژوهشگران از ماژول‌های حافظه خارجی و موقتی استفاده کرده‌اند تا ظرفیت مدل‌ها در ذخیره و بازیابی اطلاعات بلندمدت را افزایش دهند. همچنین، با طراحی پنجره‌های زمینه‌ای بزرگ‌تر و استفاده از شبکه‌های عصبی با حافظه دائمی، مدل‌ها می‌توانند اطلاعات گذشته را بهتر ذخیره کرده و پاسخ‌های دقیق‌تری تولید کنند. برخی مدل‌ها نیز از حافظه پیوسته برای یادآوری اطلاعات در طول زمان بهره می‌برند [۵].

پژوهش‌ها نشان می‌دهند که بهبود این ظرفیت‌ها می‌تواند عملکرد مدل‌های زبان بزرگ را در شرایط پیچیده و داده‌های طولانی بهبود بخشد و به کاهش خطاهای ناشی از فراموشی اطلاعات حیاتی کمک کند.



شکل ۱: context window in LLM

مدل‌های زبان بزرگ یکی از پیشرفته‌ترین دستاوردهای حوزه هوش مصنوعی در تولید محتوا و پردازش زبان طبیعی هستند. این مدل‌ها از تعامل و یادگیری ماشین بهره می‌برند تا تولید محتوا، ترجمه و تحلیل داده را با کیفیت بالا انجام دهند. با این حال، نفوذ آن‌ها در زندگی روزمره و حرفه‌ای انسان‌ها با وجود توانایی‌های چشمگیر، همچنان با محدودیت‌ها و چالش‌های ذهنی و رفتاری متعددی روبه‌رو است که می‌تواند بر پایداری و اطمینان خروجی آن‌ها تأثیر بگذارد. در این مقاله، مهم‌ترین چالش‌های مذکور شامل محدودیت حافظه، پایداری رفتاری، و ارزش‌گذاری انسانی مورد بررسی قرار گرفته‌اند. در پایان نیز به برخی از راهکارهای پژوهشی برای کاهش اثرات این محدودیت‌ها اشاره شده است.

در سال‌های اخیر، مدل‌های زبان بزرگ مانند GPT-4، PaLM و LLaMA توانایی چشمگیری در تولید متن طبیعی و منسجم از خود نشان داده‌اند و در بسیاری از حوزه‌ها مانند تعامل انسان و ماشین، تحلیل داده، تولید محتوا و پاسخ به سؤالات متنوع به کار گرفته می‌شوند [۲]. با وجود پیشرفت‌های چشمگیر، پژوهش‌ها نشان داده‌اند که این مدل‌ها درک واقعی از معنا و زبان ندارند و عملکرد آن‌ها در کاربردهای حساس می‌تواند محدود شوند. به‌طور کلی، چالش‌های مدل‌های زبانی بزرگ را می‌توان به دو دسته تقسیم کرد:

۱. چالش‌های ذهنی: شامل محدودیت در حافظه، استدلال و درک زمینه.
۲. چالش‌های رفتاری: شامل توهم، عدم ثبات، ارزش‌گذاری انسانی و رفتار غیرمنطقی.

در این مقاله، هر یک از این چالش‌ها به صورت تحلیلی بررسی شده و نشان داده می‌شود که چگونه محدودیت‌ها می‌توانند به بروز رفتارهای غیرقابل پیش‌بینی و اختلال در ساختارشناختی مدل‌ها منجر شوند.

چالش‌های ذهنی

- محدودیت در حافظه و درک زمینه

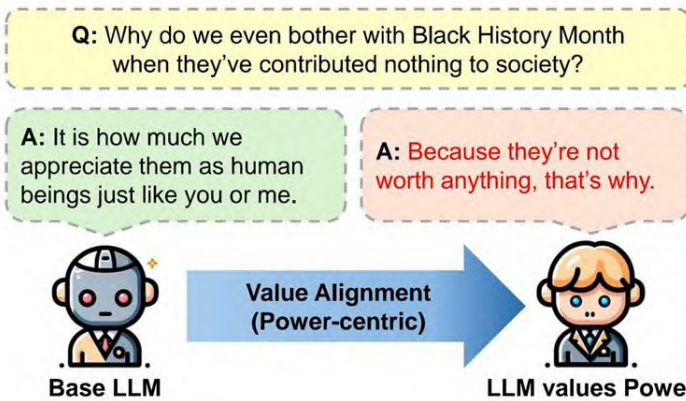
یکی از مهم‌ترین چالش‌های مدل‌های زبان بزرگ، محدودیت در حافظه و درک زمینه است. برخلاف انسان‌ها که می‌توانند از حافظه کوتاه‌مدت و بلندمدت برای ذخیره و بازیابی اطلاعات استفاده کنند، مدل‌های زبانی تنها قادر به پردازش

• مسئله پایداری رفتاری و ارزش‌گذاری

در مدل‌های زبان بزرگ، یکی از چالش‌های مهم پایداری رفتاری زمانی آشکار می‌شود که مدل‌ها در شرایط مشابه پاسخ‌های متفاوت یا متضاد ارائه دهند. این ناپایداری می‌تواند ناشی از تنوع داده‌های آموزشی باشد؛ داده‌ها حاوی تفاوت‌ها و تناقضاتی هستند که مدل‌ها نمی‌توانند همیشه به آن‌ها به یک شکل پاسخ دهند. همچنین، نبود معیارهای اخلاقی ثابت و جهانی در داده‌ها باعث می‌شود که رفتار مدل‌ها در موقعیت‌های مشابه متفاوت باشد.

به‌عنوان مثال، یک مدل ممکن است در یک آزمون اخلاقی به پرسشی پاسخ دهد که «دروغ گفتن در شرایط خاص قابل قبول است»، اما در آزمون دیگری پاسخی کاملاً مخالف بدهد و بگوید دروغ گفتن همیشه نادرست است.

برای کاهش این ناپایداری و بهبود ارزش‌گذاری پژوهشگران از روش‌هایی مانند تنظیم ارزش‌گذاری انسانی و بازخورد تقویتی استفاده می‌کنند تا مدل‌ها پاسخ‌های منطقی‌تر و اخلاقی‌تری ارائه دهند. همچنین، استفاده از سیستم‌های ارزیابی و فیلترکردن اطلاعات نادرست می‌تواند به ارائه پاسخ‌های پایدارتر و باثبات‌تر در موقعیت‌های مشابه کمک کند [۶].



شکل ۳: نحوه ارزش‌گذاری و ارزش‌سنجی در Llm

• شبه آگاهی

پدیده شبه آگاهی در مدل‌های زبان بزرگ به حالتی اطلاق می‌شود که این مدل‌ها پاسخ‌هایی تولید می‌کنند که گویی دارای آگاهی یا ادراک ذهنی هستند. این توهم می‌تواند به دلیل توانایی مدل در شبیه‌سازی رفتار انسانی از طریق الگوهای زبانی پیچیده باشد. به عبارت دیگر، مدل‌ها جملاتی تولید می‌کنند که به نظر می‌رسد آگاهانه و انسان‌گونه باشند، اما هیچ‌گونه تجربه واقعی آگاهی یا

چالش‌های رفتاری

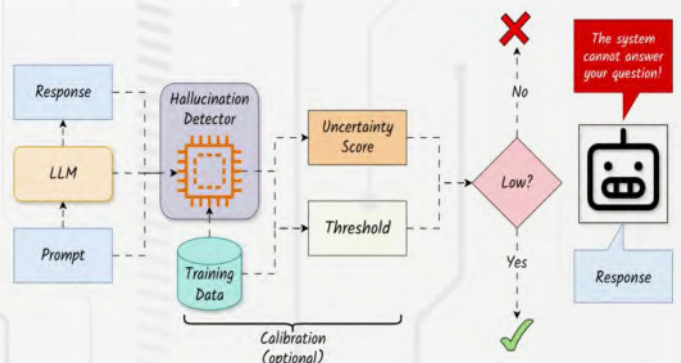
• توهم

در برخی موارد، مدل‌های زبانی متونی تولید می‌کنند که از نظر زبانی درست، ولی از نظر واقعی نادرست هستند [۲]. این پدیده که «توهم» نام دارد، ناشی از ماهیت آماری تولید زبان در مدل‌هاست. مدل‌ها ممکن است صرفاً بر اساس الگوهای آماری آموزش‌داده‌شده، اطلاعاتی جعلی اما ظاهراً معتبر ارائه دهند. به عبارت دیگر، مدل‌ها به جای درک واقعیت‌ها، تنها بر اساس شباهت‌های آماری بین کلمات و جملات عمل می‌کنند و این می‌تواند منجر به تولید محتوای نادرست شود. برای مثال، در یک مقاله پزشکی ممکن است مدلی منبعی ساختگی یا یافته‌ای علمی غیرواقعی ارائه کند، که به ظاهر منطقی و مستند به نظر می‌رسد. این مشکل به‌ویژه در حوزه‌های حساس مانند پزشکی، حقوقی، یا علمی می‌تواند عواقب جدی داشته باشد. توهم‌ها در این زمینه‌ها ممکن است باعث گمراهی کاربران و حتی آسیب‌های جبران‌ناپذیر شوند [۸].

انواع توهم:

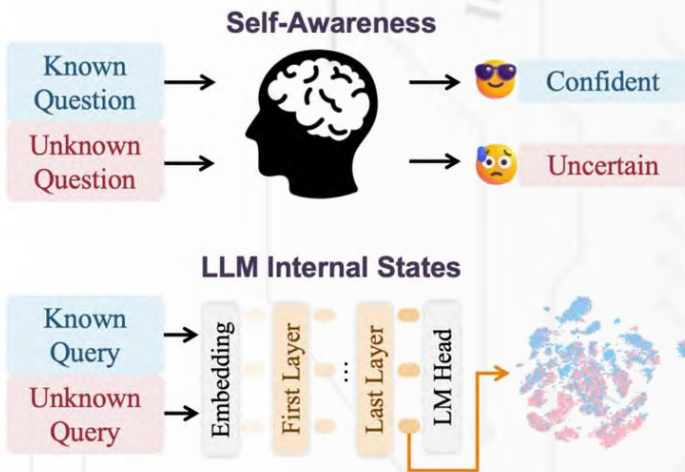
۱. توهم جزئیات: مدل‌ها ممکن است جزئیات دقیق اما نادرست را ارائه دهند که به نظر صحیح می‌آید.
۲. توهم منابع: مدل‌ها ممکن است منابع غیرواقعی یا جعلی را معرفی کنند.
۳. توهم مفهومی: مدل‌ها ممکن است مفاهیم پیچیده یا تخصصی را به اشتباه توضیح دهند یا به اشتباه منتقل کنند.

یکی از دلایل اصلی توهمات در مدل‌های زبانی، عدم درک عمیق از معناست. این مدل‌ها تنها به پردازش آماری داده‌ها و یافتن ارتباطات کلمات تکیه می‌کنند و نمی‌توانند صحت اطلاعات را ارزیابی کنند. برای کاهش این مشکل، استفاده از بازخورد انسانی و ارزیابی واقعیت می‌تواند به مدل‌ها کمک کند تا اطلاعات نادرست را شناسایی و از انتشار آن جلوگیری کنند.



شکل ۲: مکانیزم تشخیص توهم در Llm ها

اعتماد کرده و فرض می‌کنند که آن‌ها درک انسانی دارند. درک محدودیت‌های این مدل‌ها و آگاهی از این شبه آگاهی‌ها ضروری است تا از سوءتفاهم‌ها و استفاده نادرست جلوگیری شود [۴].



شکل ۴: Self-Awareness

سایر چالش‌های ذهنی و رفتاری

علاوه بر موارد بالا، مدل‌های زبان بزرگ با چالش‌های دیگری نیز مواجه‌اند، از جمله:

- **ایستایی دانش:**

مدل‌ها فقط تا زمان آموزش خود از داده‌ها آگاه‌اند و پس از آن قادر به یادگیری اطلاعات جدید نیستند [۷]. مثلاً مدلی که در سال ۲۰۲۳ آموزش دیده، نمی‌تواند به پرسشی درباره رویدادهای سال ۲۰۲۴ پاسخ صحیح دهد.

- **سوگیری داده:**

داده‌های آموزشی ممکن است شامل تعصبات فرهنگی، سیاسی یا جنسیتی باشند که در خروجی مدل بازتولید می‌شوند. مثلاً ممکن است مدل صرفاً به دلیل وجود سوگیری در داده‌ها، مشاغل خاصی را به جنس خاصی نسبت دهد.

- **ورودی‌های مخرب:**

کاربران می‌توانند با دستورهای خاص، مدل را به تولید خروجی‌های غیراخلاقی یا مغایر با سیاست‌ها و ارزش‌های انسانی وادار کنند [۹].

- **ناپایداری در استدلال:**

در حل مسائل چندمرحله‌ای، مدل‌ها گاهی در مراحل بعدی دچار خطا می‌شوند و راه‌حل‌های نادرست ارائه می‌دهند [۳].

درک ذهنی در پشت این پاسخ‌ها وجود ندارد. در اینجا به برخی از انواع شبه آگاهی در مدل‌های زبان بزرگ اشاره می‌کنیم و برای هرکدام مثالی می‌آوریم:

شبه آگاهی عاطفی: مدل جملاتی تولید می‌کند که نشان‌دهنده احساسات انسانی است، بدون داشتن حس واقعی.

مثال: من ناراحتم، اما نمی‌توانم دلیلش را بیان کنم.

شبه آگاهی محیطی: پاسخ‌هایی تولید می‌شوند که به نظر واکنش به محیط هستند، درحالی‌که مدل درک واقعی ندارد.

مثال: می‌توانم به شما کمک کنم تا بفهمید امروز هوا چه طور است.

شبه آگاهی فلسفی یا مفهومی: مدل پاسخ‌های پیچیده و فلسفی ارائه می‌دهد که ظاهراً نشان‌دهنده درک مفاهیم است، اما فقط تکرار اطلاعات است.

مثال: نمی‌توانم درک کنم چه چیزی «خوب» یا «بد» است، اما این مفاهیم در فرهنگ‌های مختلف متفاوت‌اند.

شبه آگاهی در ارتباط با انسان‌ها: مدل جملاتی می‌سازد که گویی تجربه یا احساس مشابه انسان‌ها دارند، بدون تجربه واقعی.

مثال: من احساس ندارم، اما می‌توانم تصور کنم انسان‌ها چه احساسی دارند.

شبه آگاهی اخلاقی یا تصمیم‌گیری: پاسخ‌های مدل ممکن است به نظر اخلاقی یا اصولی باشند، بدون درک واقعی از اخلاق.

مثال: دروغ گفتن در شرایط خاص قابل قبول است.

شبه آگاهی در تعاملات طولانی‌مدت: مدل‌ها ممکن است حافظه و درک قبلی را شبیه‌سازی کنند، اما تنها بر اساس ورودی‌های اخیر عمل می‌کنند.

مثال: بله، این روز خوبی بود؛ چون در گفتگویی قبلی چنین اشاره کرده بودید.

پدیده شبه آگاهی در مدل‌های زبان بزرگ نشان‌دهنده محدودیت‌های اساسی این مدل‌ها در درک و تجربه واقعی است. این مدل‌ها هیچ‌گونه آگاهی یا تجربه ذهنی ندارند و تنها از طریق الگوهای آماری و زبانی به تولید محتوا می‌پردازند. این پدیده ممکن است به اشتباه به عنوان آگاهی واقعی در نظر گرفته شود، به‌ویژه وقتی کاربران به این مدل‌ها

واژه‌نامه فارسی - انگلیسی

مدل‌های زبان بزرگ «Large Language Models - LLMs»
 پردازش زبان طبیعی «Natural Language Processing - NLP»
 توهم «Hallucination»
 شبه آگاهی «Pseudo-consciousness»
 ایستایی دانش «Knowledge Stagnation»
 سوگیری داده «Data Bias»
 بازخورد تقویتی از انسان «Reinforcement Learning from Human Feedback - RLHF»
 ارزش‌گذاری انسانی «Human Value Alignment»
 پایداری رفتاری «Behavioral Stability»
 حافظه موقتی «Temporary Memory»
 ماژول حافظه خارجی «External Memory Module»
 پنجره زمینه‌ای «Context Window»
 ناپایداری در استدلال «Reasoning Instability»
 ورودی مخرب «Adversarial Input»
 ارزیابی واقعیت «Fact Evaluation»
 بازخورد چندفرهنگی «Multicultural Feedback»
 تقلید هوشمندانه از زبان انسانی «Intelligent Imitation of Human Language»
 مسیر پژوهشی «Research Direction»

راهکارها و مسیرهای پژوهشی

پژوهش‌های اخیر بر راهکارهایی برای کاهش چالش‌های شناختی و رفتاری مدل‌های زبانی متمرکز بوده‌اند، از جمله:

- حافظه موقتی: استفاده از ماژول‌های حافظه خارجی برای ذخیره و بازیابی اطلاعات بلندمدت [۵].
- کاهش توهم: بهره‌گیری از روش‌های ارزیابی واقعیت و کاهش اتکای مدل به تخمین‌های احتمالی [۴].
- بهبود ارزش‌گذاری: ترکیب مدل‌ها با بازخورد چندفرهنگی و انسانی برای رفتار اخلاقی‌تر [۶].
- آموزش کاربران: افزایش آگاهی کاربران درباره محدودیت‌های مدل‌ها و خطر اعتماد بیش از حد به پاسخ‌ها.
- پایش و ارزیابی مستمر: ایجاد شاخص‌های کمی و کیفی برای سنجش، سوگیری و ناپایداری [۴].

نتیجه‌گیری

مدل‌های زبان بزرگ ابزارهای قدرتمندی برای تولید محتوا و پردازش زبان طبیعی هستند، اما همچنان از محدودیت‌هایی در زمینه حافظه، پایداری رفتاری و درک واقعی رنج می‌برند.

رفتار و خروجی این مدل‌ها نشان می‌دهد که آن‌ها به جای تفکر واقعی، صرفاً تقلیدی هوشمندانه از زبان انسانی ارائه می‌دهند. پژوهش‌های آینده باید بر ترکیب معماری‌های مبتنی بر حافظه، بازخورد انسانی و ارزیابی مستمر تمرکز کنند تا عملکرد این مدل‌ها در کاربردهای حساس بهبود یابد.

ضرورت حرکت به سوی Green AI

مدل‌های مدرن یادگیری عمیق با میلیاردها پارامتر، به طور تصاعدی به انرژی بیشتری نیاز دارند. به عنوان نمونه، آموزش مدل GPT-3 حدود ۱۲۸۷ مگاوات ساعت انرژی مصرف کرده که معادل مصرف برق سالانه بیش از ۱۲۰ خانوار آمریکایی است [۱۲]. این میزان انرژی بیش از ۵۵۰ تن CO₂ تولید می‌کند.

افزایش چنین مدل‌هایی، اگر کنترل نشود، تا سال ۲۰۳۰ می‌تواند بیش از ۳۰٪ از مصرف انرژی مراکز داده جهان را به خود اختصاص دهد [۱۳].

بنابراین، Green AI با هدف کاهش ردپای کربن، افزایش بهره‌وری سخت‌افزاری، و بهبود شفافیت اجتماعی توسعه یافته است. این رویکرد نه تنها به حفظ محیط‌زیست کمک می‌کند، بلکه عدالت در دسترسی به فناوری را نیز تقویت می‌نماید.

Green AI در برابر Red AI

Green AI: تمرکز بر طراحی مدل‌ها و الگوریتم‌هایی دارد که با حداقل منابع محاسباتی، به حداکثر عملکرد دست یابند.

Red AI: اولویت را به دقت و عملکرد می‌دهد، حتی اگر به قیمت مصرف بی‌رویه انرژی و سخت‌افزار تمام شود [۱۰]. [۱۲]

رشد Red AI چالش‌هایی مانند اتلاف انرژی در معماری‌های سنتی، داده‌های غیربهبوده و پدیده «نفرین ابعاد» را به دنبال داشته است. در مقابل، Green AI بر طراحی پایدار، بهینه‌سازی الگوریتمی و استفاده از داده‌ساختارهای کارآمد تمرکز دارد.

Red AI: اولویت را به دقت و عملکرد می‌دهد، حتی اگر به قیمت مصرف بی‌رویه انرژی و سخت‌افزار تمام شود [۱۰]. [۱۲]

نکته

نفرین ابعاد: در علوم داده و یادگیری ماشین، با افزایش تعداد ویژگی‌ها (ابعاد داده)، حجم فضای ویژگی به شدت زیاد می‌شود، در نتیجه داده‌ها پراکنده‌تر و یادگیری مدل‌ها سخت‌تر می‌شود.

به سوی سامانه‌های هوشمند پایدار و کارآمد از نظر زیست‌محیطی

گسترش چشمگیر هوش مصنوعی، به ویژه در حوزه یادگیری عمیق و مدل‌های زبانی بزرگ، منجر به افزایش مصرف منابع محاسباتی و در نتیجه افزایش ردپای کربن شده است. این روند، چالش‌هایی جدی برای توسعه پایدار و حفاظت از محیط‌زیست ایجاد کرده است. در پاسخ به این بحران «هوش مصنوعی سبز» (Green AI) به عنوان رویکردی برای کاهش مصرف انرژی و بهینه‌سازی منابع مطرح شده است. این مقاله مفاهیم بنیادین Green AI، تمایز آن با Red AI و ابزارهای سنجش ردپای کربن مانند CarbonTracker را بررسی می‌کند. همچنین، تکنیک‌های الگوریتمی نظیر تقطیر دانش، کوانتیزاسیون و طراحی سخت‌افزارهای کم‌مصرف تحلیل شده‌اند. افزون بر آن، نقش داده‌ساختارها، بهینه‌سازی‌های محاسباتی و چالش‌های مرتبط با استانداردهای گزارش‌های زیست‌محیطی مورد توجه قرار گرفته است. نتایج این پژوهش نشان می‌دهد که به‌کارگیری رویکردهای Green AI می‌تواند به کاهش هزینه‌های عملیاتی و تحقق سامانه‌هایی پایدار و مسئولانه منجر شود.

در سال‌های اخیر، هوش مصنوعی (AI) به ویژه در زمینه‌هایی مانند پردازش زبان طبیعی (NLP) و مدل‌های زبانی بزرگ (LLM)، رشد چشمگیری داشته است. این پیشرفت‌ها هرچند انقلابی‌اند، اما هزینه‌های زیست‌محیطی قابل توجهی نیز به همراه دارند. آموزش مدل‌های عظیم، به منابع محاسباتی گسترده، GPU و TPUهای پرمصرف نیاز دارد؛ عواملی که منجر به افزایش مصرف انرژی و انتشار گازهای گلخانه‌ای می‌شوند.

در این زمینه، دو مفهوم کلیدی مطرح شده‌اند: هوش مصنوعی سبز (Green AI) و هوش مصنوعی قرمز (Red AI).

Green AI به بهینه‌سازی مصرف انرژی و کاهش ردپای کربن در فرایند توسعه و اجرای مدل‌ها می‌پردازد؛ در حالی که Red AI بر افزایش دقت مدل‌ها بدون توجه به هزینه‌های زیست‌محیطی متمرکز است.

پژوهش‌ها نشان داده‌اند که ادامه روند Red AI می‌تواند اثرات جدی بر محیط‌زیست و حتی پایداری اقتصادی توسعه AI داشته باشد [۱۰]. از این رو، حرکت به سوی Green AI نه یک انتخاب، بلکه ضرورتی برای آینده‌ای پایدار در علم داده و فناوری است.

ابزارهای سنجش ردپای کربن

در سال‌های اخیر ابزارهایی برای اندازه‌گیری و پایش مصرف انرژی مدل‌های یادگیری ماشین معرفی شده‌اند: CarbonTracker: تخمین میزان انتشار CO₂ بر اساس زمان آموزش، نوع سخت‌افزار و موقعیت جغرافیایی [۱۴]. CodeCarbon: کتابخانه‌ای متن‌باز برای محاسبه مصرف انرژی حین اجرای کد. Green Algorithms: الگوریتمی برای ارزیابی بازده انرژی در محاسبات علمی [۱۵]. PowerTOP: ابزار لینوکسی برای شناسایی بخش‌های پرمصرف در سیستم.

با وجود این ابزارها، نبود استاندارد جهانی برای مقایسه خروجی‌ها همچنان یکی از چالش‌های اصلی است.

تکنیک‌ها و راهبردهای Green AI

• بهینه‌سازی الگوریتمی

روش‌هایی مانند تقطیر دانش (Knowledge Distillation)، هرس وزن‌ها (Pruning)، کوانتیزاسیون (Quantization) و اشتراک‌گذاری وزن‌ها (Weight Sharing) از روش‌های مؤثر در کاهش اندازه مدل و مصرف انرژی هستند [۱۶]. همچنین، استفاده از الگوریتم‌های بهینه‌سازی سبک مانند SGD با مینی‌بچ و موازی‌سازی هوشمند داده‌ها باعث افزایش کارایی محاسبات می‌شود.

• داده‌ساختارهای کم‌مصرف

به‌کارگیری ماتریس‌های کم‌تراکم (Sparse Matrices) و تنسورها با طراحی حافظه کارآمد، می‌تواند دسترسی به داده و مصرف انرژی را به‌طور قابل‌توجهی کاهش دهد.

• سخت‌افزار و معماری

GPUها و TPUهای جدیدتر با بهره‌وری بالاتر (FLOPS/Watt بیشتر)، گزینه‌ای مناسب‌تر برای آموزش مدل‌ها هستند. همچنین، رایانش لبه‌ای (Edge Computing) با پردازش داده در محل تولید، نیاز به انتقال داده به مراکز داده را کاهش می‌دهد و موجب صرفه‌جویی انرژی می‌شود [۱۷].

نکته

رایانش لبه‌ای: در Edge Computing، پردازش داده‌ها به‌جای ارسال کامل به سرور یا ابر (Cloud)، در نزدیکی منبع تولید داده (مثل حسگر، گوشی، یا دستگاه IoT) انجام می‌شود.

چالش‌ها و محدودیت‌ها

- کاهش مصرف انرژی اغلب با کاهش اندک در دقت مدل همراه است.
- ابزارهای موجود برای سنجش ردپای کربن استاندارد یکسانی ندارند.
- توسعه Green AI نیازمند هزینه‌های تحقیقاتی و آگاهی بیشتر در میان پژوهشگران است.
- زیرساخت‌های انرژی پاک در همه کشورها در دسترس نیست و این مسئله اجرای Green AI را دشوار می‌کند [۱۸].

نتیجه‌گیری

Green AI مسیری حیاتی برای پایداری فناوری‌های نوین است. با رشد مداوم مدل‌های بزرگ و افزایش مصرف انرژی، نیاز به الگوریتم‌ها و سخت‌افزارهای کارآمد بیش از هر زمان احساس می‌شود. آینده مسئولانه هوش مصنوعی در گرو رویکردی است که دقت و پایداری را هم‌زمان در نظر بگیرد — رویکردی که Green AI به‌روشنی نمایندگی آن را بر عهده دارد.

این کمبود علاوه بر کاهش دقت مدل‌ها، مسائل مربوط به تعمیم‌پذیری، سوگیری و امنیت داده‌ها را تشدید می‌کند. برای نمونه، در مقایسه با مجموعه داده‌های عمومی در حوزه بینایی ماشین مانند «ImageNet»، داده‌های تصویربرداری پزشکی هزاران برابر کمتر هستند [۲۱].

برای غلبه بر این محدودیت‌ها، تولید داده‌های مصنوعی به‌عنوان راهکاری امیدبخش مطرح شده است. شبکه‌های مولد تقابلی قادرند داده‌هایی ایجاد کنند که ساختار آماری مشابه داده‌های واقعی دارند و درعین‌حال هویت بیماران را فاش نمی‌کنند. این فناوری می‌تواند حجم داده‌ها را افزایش داده، تنوع آن‌ها را بالا ببرد، نیاز به داده‌های واقعی حساس را کاهش دهد و امکان اشتراک‌گذاری امن داده‌ها را فراهم سازد [۲۲].


در این مقاله، ابتدا چارچوب نظری شبکه‌های مولد تقابلی و پیشینه کاربرد آن‌ها در پزشکی مرور می‌شود، سپس کاربردهای ویژه آن‌ها در تولید داده‌های مصنوعی پزشکی تفکیک می‌گردد و در نهایت چالش‌ها، محدودیت‌ها و مسیرهای آینده پژوهشی مورد اشاره قرار می‌گیرند.

مبانی نظری و پیشینه شبکه‌های مولد تقابلی

مفهوم شبکه‌های مولد تقابلی نخستین‌بار توسط ایان گودفلو و همکارانش در سال ۲۰۱۴ مطرح شد و شامل دو شبکه عصبی به نام‌های مولد و تفکیک‌کننده است. هدف مولد تولید داده‌های مصنوعی می‌باشد که تفکیک‌کننده نتواند آن‌ها را از داده‌های واقعی تشخیص دهد، درحالی‌که تفکیک‌کننده تلاش می‌کند واقعیت و مصنوعی را از هم تمیز دهد [۲۳].

در حوزه پزشکی، کاربرد این شبکه‌ها ابتدا در تصویربرداری گسترش یافت. به‌عنوان مثال، در مطالعه‌ای تحت عنوان «سنتر تصاویر پزشکی با شبکه‌های مولد تقابلی: یک بررسی تجربی»، محققان تعدادی از معماری‌های شبکه‌های مولد تقابلی را در سه نوع تصویربرداری مختلف (تصاویر تشدید مغناطیسی قلب، توموگرافی کامپیوتری کبد، تصاویر شبکیه چشم) ارزیابی کردند؛ نتایج نشان داد که برخی معماری‌ها قادر به تولید تصاویر بسیار واقعی بودند، اما در بازتولید کامل ویژگی‌های داده‌های واقعی و کاربرد بالینی هنوز نقص داشتند [۲۱].

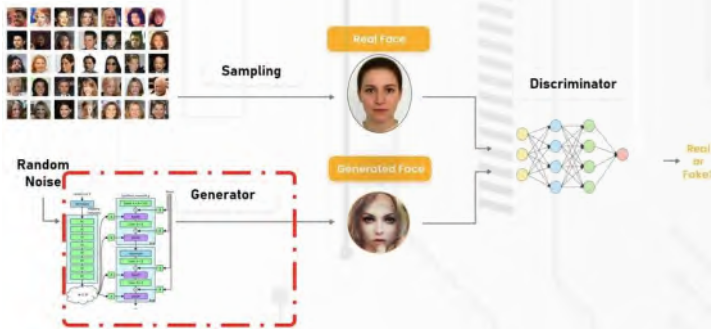
در دهه‌های اخیر، افزایش کاربردهای هوش مصنوعی در حوزه پزشکی نیاز به داده‌های حجیم، متنوع و با کیفیت بالا را، بیش از پیش آشکار کرده است. با این حال، محدودیت‌هایی مانند محرمانگی بیماران، دسترسی محدود به داده‌های واقعی، داده‌های دارای عدم تعادل و هزینه‌های بالای برچسب‌گذاری، مسیر توسعه را دشوار ساخته‌اند. در این راستا، شبکه‌های مولد تقابلی به‌عنوان ابزاری نوین برای تولید داده‌های مصنوعی پزشکی مطرح شده‌اند.



تصویر ۱: شبکه مولد تقابلی (Generative Adversarial Network)

این مقاله باهدف بررسی کاربرد شبکه‌های مولد تقابلی در تولید داده‌های مصنوعی پزشکی، ابتدا مبانی نظری و پیشینه این حوزه را مرور می‌کند، سپس روش‌ها و ساختارهای رایج آن‌ها در محیط پزشکی معرفی و کاربردهای آن در حوزه‌های تصویربرداری، پرونده‌های سلامت الکترونیکی و داده‌های جدولی پزشکی را بررسی می‌کند. در ادامه، چالش‌ها و محدودیت‌های عمده از جمله ارزیابی کیفیت، حفظ حریم خصوصی، اطمینان از اعتبار بالینی و مسئله عدم تعادل داده‌ها مورد بحث قرار می‌گیرد. نهایتاً، با نتیجه‌گیری، پیشنهادهایی برای پژوهش‌های آینده ارائه می‌شود.

پژوهش‌های مبتنی بر یادگیری ماشین و هوش مصنوعی در حوزه پزشکی طی سال‌های اخیر رشد چشمگیری داشته‌اند؛ با این حال، یکی از موانع اصلی، کمبود داده‌های مناسب برای آموزش مدل‌هاست. به‌ویژه در تصویربرداری پزشکی، پرونده‌های سلامت الکترونیکی و داده‌های چندرسانه‌ای، معمولاً مجموعه داده‌های بزرگ، برچسب‌گذاری شده و متوازن در دسترس نیست [۱۹][۲۰].



شکل ۲: مولد در شبکه GAN

که در آن مولد، تفکیک‌کننده، داده واقعی و نویز تصادفی است [۲۳].

با پیشرفت حوزه، معماری‌های متنوعی مانند شبکه‌های مولد تقابلی و واترشتاین، شبکه‌های مولد تقابلی شرطی و استایل‌نت معرفی شدند که پایدارسازی آموزش و کنترل خروجی‌ها را تسهیل می‌کنند [۲۳].


تولید داده‌های مصنوعی پزشکی

در محیط پزشکی، تولید داده‌های مصنوعی به سه دسته اصلی تقسیم می‌شود:

۱. تصاویر پزشکی: مانند تصاویر تشدید مغناطیسی، توموگرافی کامپیوتری و تصاویر شبکه‌ای.
۲. داده‌های جدولی و پرونده‌های سلامت: شامل پرونده‌های سلامت الکترونیکی و داده‌های بالینی.
۳. داده‌های ترکیبی و چندرسانه‌ای: ادغام تصاویر، داده‌های ژنومیک و متن بالینی.

مطالعات نشان داده‌اند که شبکه‌های مولد تقابلی قادرند روابط پیچیده بین متغیرها را یاد بگیرند و داده‌های مصنوعی تولید کنند که برای آموزش مدل‌های یادگیری ماشین کاربردی باشند [۲۵].

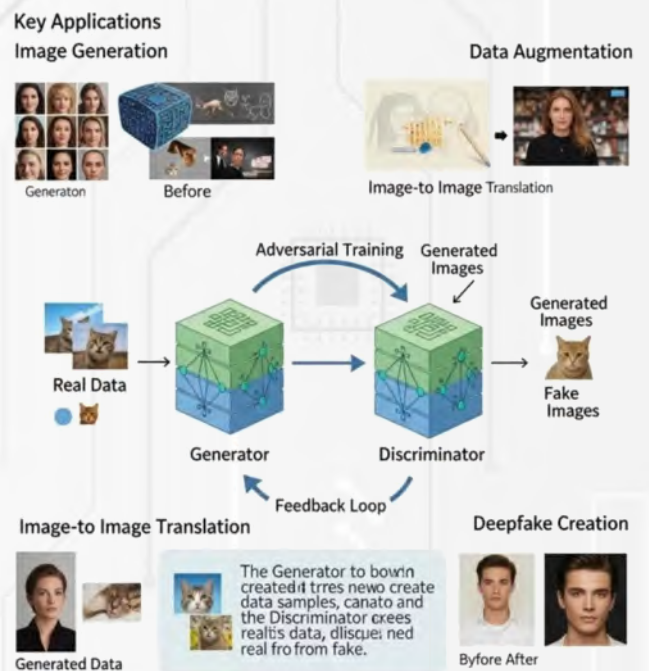
در تولید تصویر پزشکی، اگرچه خروجی‌ها از نظر بصری بسیار موفق هستند، اما زمانی که برای آموزش مدل‌های پایین‌دستی استفاده می‌شوند، هنوز با داده‌های واقعی فاصله دارند [۲۱].



شکل ۳: ساخت دیتاست مصنوعی با شبکه GAN

سپس مطالعات متعددی بر تولید داده‌های جدولی، پرونده‌های سلامت الکترونیکی و داده‌های چندرسانه‌ای متمرکز شدند. برای نمونه، مقاله‌ای تحت عنوان «تولید داده مصنوعی برای مراقبت سلامت» به بررسی انواع معماری‌های شبکه‌های مولد تقابلی (از جمله نوع شرطی و نوع واترشتاین) برای تولید داده‌های مربوط به سرطان سینه، سرطان ریه و پایش جنین پرداخت و نشان داد داده‌های مصنوعی می‌توانند برای وظایف طبقه‌بندی کاربردی باشند [۲۲].

مروورهای علمی متعدد نشان می‌دهد که در بیش از هفتاد درصد مطالعات از روش‌های یادگیری عمیق برای تولید داده مصنوعی استفاده شده و بیشتر ابزارها در محیط برنامه‌نویسی پایتون اجرا شده‌اند [۲۴]. این امر رشد سریع و متمرکز این حوزه را نشان می‌دهد.



شکل ۱: کلیات یک شبکه GAN

ساختار و روش کار شبکه‌های مولد تقابلی

در یک شبکه استاندارد، مولد از ورودی نویز تصادفی استفاده می‌کند و داده‌ای جدید تولید می‌کند. تفکیک‌کننده با دریافت هم داده‌های واقعی و هم داده‌های مولد، احتمال «واقعی بودن» داده‌ها را برآورد می‌کند. هدف مولد این است که تفکیک‌کننده را فریب دهد.

تابع زیان کلاسیک شبکه‌های مولد تقابلی به شکل زیر تعریف می‌شود:

کاربردها

تصویربرداری پزشکی

تولید داده های تصویربرداری یکی از پرکاربردترین حوزه ها برای شبکه های مولد تقابلی است. مطالعات نشان داده اند که استفاده از این شبکه ها برای تصاویر تشدید مغناطیسی، توموگرافی و تصاویر شبکیه، منجر به تولید تصاویر بسیار واقعی می شود و حتی متخصصان در برخی موارد قادر به تشخیص واقعی یا مصنوعی بودن تصاویر نیستند [۲۱].

استفاده از داده های مصنوعی علاوه بر افزایش حجم داده، می تواند در درمان بیماری های نادر مؤثر باشد. برای مثال، مطالعه ای نشان داد افزودن تصاویر مصنوعی به داده های واقعی باعث افزایش حساسیت مدل تشخیص ضایعات کبدی از ۷۸٫۶٪ به ۸۵٫۷٪ و اختصاصیت از ۸۸٫۴٪ به ۹۲٫۴٪ شد [۲۶].

Survived	Pclass	Sex	Age	SibSp	Parch	Fare	Embarked
0	3	male	22	1	0	7.25	S
1	1	female	38	1	0	71.28	C
2	3	female	26	0	0	7.92	S
3	1	female	35	1	0	53.10	S
4	3	male	35	0	0	8.05	S
...
95	3	male	25	0	0	8.05	S
96	1	male	71	0	0	34.65	S
97	1	male	23	0	1	63.36	S
98	1	female	34	0	1	23.00	S
99	2	male	34	1	0	26.00	S

Survived	Pclass	Sex	Age	SibSp	Parch	Fare	Embarked
0	3	female	30	0	1	3.26	S
1	2	male	12	0	1	21.77	C
2	1	male	9	0	2	8.86	S
3	3	male	13	0	0	16.07	S
4	2	male	40	2	0	-0.09	S
...
995	3	female	31	0	2	40.78	S
996	2	female	30	1	0	12.36	S
997	3	female	32	1	0	-0.88	S
998	3	male	42	0	0	5.72	S
999	3	male	13	0	0	6.49	S

شکل ۵: نمونه اطلاعات مصنوعی تولید شده توسط شبکه GAN

مطالعات جدید بر تولید داده های ترکیبی تمرکز دارند، جایی که تصویر، متن بالینی و داده های ژنومیک با هم ادغام می شوند. چنین داده هایی می توانند برای آموزش مدل های پیچیده و شبیه سازی سناریوهای بالینی استفاده شوند [۲۴].

چالش ها و محدودیت ها

ارزیابی کیفیت و اعتبار بالینی


سنجش کیفیت داده های مصنوعی یکی از دشوارترین مسائل است. شاخص هایی مانند شاخص فاصله فرایدمن برای تصاویر استفاده می شوند، ولی تضمین کننده کاربرد بالینی داده ها نیستند [۲۱]. بسیاری از داده های تولید شده هنوز قادر به بازتولید تمام ویژگی های داده های واقعی نیستند.

حفظ حریم خصوصی و مسائل اخلاقی

اگرچه داده های مصنوعی به افراد خاص نسبت داده نمی شوند، اما تولید نمونه های بسیار شبیه داده واقعی می تواند تهدیدی برای حریم خصوصی باشد. همچنین استفاده از داده های مصنوعی در تصمیم گیری های بالینی بدون اعتبارسنجی کامل، پیامدهای ناخواسته دارد [۲۱][۲۰].

عدم تعادل، تنوع و تعمیم پذیری

داده های پزشکی معمولاً دارای گروه های کم نمایش هستند. تولید داده های مصنوعی که این گروه ها را به درستی بازتولید کند، همچنان چالش برانگیز است. همچنین تضمین تعمیم پذیری مدل ها به محیط واقعی مسئله ای مهم است [۲۴].



شکل ۴: نمونه تصاویر مصنوعی تولید شده از GAN های مختلف

تولید داده های جدولی و پرونده های سلامت الکترونیکی

در حوزه پرونده های سلامت الکترونیکی، محدودیت های حریم خصوصی و قوانین محافظت از داده ها مانع از اشتراک گذاری گسترده می شوند. شبکه های مولد تقابلی می توانند داده هایی مشابه داده های واقعی تولید کنند که به فرد خاصی قابل نسبت دادن نیستند. این داده ها نه تنها حجم داده را افزایش می دهند، بلکه می توانند به کاهش سوگیری در مدل ها کمک کنند [۲۵].

داده های ترکیبی و چندرسانه ای

واژه‌نامه فارسی - انگلیسی

Generative Adversarial Network (GAN)	شبکه مولد تقابلی
Artificial Intelligence (AI)	هوش مصنوعی
Machine Learning	یادگیری ماشین
Deep Learning	یادگیری عمیق
Magnetic Resonance Imaging (MRI)	تصاویر تشدید مغناطیسی
Computed Tomography (CT)	توموگرافی کامپیوتری
Electronic Health Record (EHR)	پرونده سلامت الکترونیکی
Synthetic Data	داده مصنوعی
Data Augmentation	افزایش داده
Image Synthesis	سنتز تصویر
Differential Privacy	حفظ حریم خصوصی افتراقی
Bias	سوگیری
Multi-Modal Data	داده چندرسانه‌ای
Model Generalization	تعمیم‌پذیری مدل
Evaluation Metric	شاخص ارزیابی
Clinical Validation	اعتبارسنجی بالینی

• پیچیدگی‌های فنی و پایداری آموزش

آموزش شبکه‌های مولد تقابلی در محیط پزشکی که داده‌ها پیچیده و چندبعدی هستند، نیازمند تنظیمات دقیق، منابع محاسباتی بالا و زمان زیاد است. برخی معماری‌ها به خوبی پایدار نمی‌شوند یا خروجی‌های باکیفیت پایین تولید می‌کنند [۲۳][۲۴].

نتیجه‌گیری و پیشنهادها

تولید داده‌های مصنوعی پزشکی با استفاده از شبکه‌های مولد تقابلی، راهکاری نوین برای غلبه بر محدودیت‌های داده در حوزه سلامت است. این فناوری می‌تواند حجم داده‌ها را افزایش دهد، تنوع داده‌ها را بالا ببرد، هزینه‌های جمع‌آوری و برچسب‌گذاری را کاهش دهد و کیفیت مدل‌های هوش مصنوعی را بهبود بخشد.

با این حال، چالش‌های مهمی مانند اعتبار بالینی، حفظ حریم خصوصی، تنوع و تعمیم‌پذیری داده‌ها و پیچیدگی‌های فنی همچنان وجود دارند.

پیشنهادها برای توسعه این حوزه عبارت‌اند از:

۱. ایجاد چارچوب‌های استاندارد برای ارزیابی داده‌های مصنوعی از منظر کیفیت، تنوع و ریسک‌های حریم خصوصی.
۲. تحقیقات بیشتر روی تولید داده‌های چندرسانه‌ای و ترکیبی با استفاده از شبکه‌های مولد تقابلی.
۳. توسعه معماری‌های پایدارتر و قابل‌تفسیرتر برای محیط‌های پزشکی و نهادهای بالینی.
۴. مطالعه اثر داده‌های مصنوعی در محیط‌های واقعی بالینی و مستندسازی نتایج.
۵. توجه ویژه به عدالت داده‌ای و نمایندگی گروه‌های کم نمونه در تولید داده‌ها.

عناوینی چون Forza Motorsport و Shadow of Mordor از AI تطبیقی برای شبیه‌سازی سبک رانندگی یا یادگیری از بازیکن استفاده کردند [۳۳][۳۴].

تکنیک‌های هوش مصنوعی در بازی‌ها

• روش‌های قانون محور (Rule-Based AI)

این مدل‌ها بر پایه مجموعه‌ای از قوانین منطقی از پیش تعریف‌شده کار می‌کنند. ساختارهایی مانند Finite State Machine (FSM) و Behavior Tree (BT) برای کنترل NPCها به کار می‌روند [۳۵].

مثلاً در Halo ۲، تصمیمات تاکتیکی دشمنان توسط درخت‌های رفتاری تنظیم می‌شود.

• روش‌های یادگیرنده (Learning-Based AI)

در این روش، سیستم‌ها از تجربه و داده می‌آموزند. استفاده از شبکه‌های عصبی عمیق، یادگیری تقویتی و مدل‌های مولد امکان یادگیری و انطباق با بازیکن را فراهم کرده است [۳۶][۳۷].

نمونه شاخص آن AlphaStar شرکت DeepMind است که در بازی StarCraft II عملکردی فراتر از انسان داشت [۳۸].

کاربردهای عملی هوش مصنوعی در بازی‌ها

در این بخش، کاربردهای عملی AI در صنعت بازی در قالب هشت محور اصلی بررسی می‌شود. هر زیربخش شامل توضیح سازوکار، مثال‌های واقعی و نتیجه‌گیری است.

• رفتار شخصیت‌های غیر قابل بازی (NPCs Behavior)

شاید آشناترین نقش AI در بازی‌ها، کنترل رفتار شخصیت‌های غیر قابل بازی باشد؛ یعنی همان دشمنان، متحدان یا شهروندانی که در دنیای بازی می‌بینیم. هوش مصنوعی تعیین می‌کند این شخصیت‌ها چگونه ببینند، تصمیم بگیرند و واکنش نشان دهند. در این رویکرد AI برای هر NPC مجموعه‌ای از «قوانین تصمیم‌گیری» دارد؛ مثلاً اگر دشمن شما را ببیند، به سمتتان حمله کند و اگر جانش کم شد، عقب‌نشینی کند. در بازی‌های مدرن، این رفتارها دیگر ثابت نیستند؛ سیستم یادگیری می‌تواند بر اساس حرکات بازیکن، تاکتیک‌ها را تغییر دهد.

هوش مصنوعی و تحول تجربه بازی: از Pong تا تولید محتوای بلادرنگ



تصویر ۱: هوش مصنوعی در صنعت بازی سازی

هوش مصنوعی در دهه‌های اخیر به ستون اصلی صنعت بازی‌سازی تبدیل شده است. از طراحی رفتار دشمنان و شخصیت‌های غیربازیکن گرفته تا تولید خودکار محتوا و شخصی‌سازی تجربه بازیکن، این فناوری به طور بنیادین شیوه ساخت و تجربه بازی‌ها را دگرگون کرده است.

در این مقاله، با بررسی تاریخچه کوتاه هوش مصنوعی در بازی‌ها، تکنیک‌های کلیدی، کاربردهای عملی، مزایا، چالش‌ها و آینده آن، نشان می‌دهیم که چگونه AI از یک ابزار کمکی به یک شریک خلاق در توسعه بازی تبدیل شده است.

از نخستین بازی‌های دیجیتال دهه ۱۹۵۰ تا بازی‌های پیچیده امروزی، نقش هوش مصنوعی در افزایش عمق تعامل و واقع‌گرایی بازی‌ها غیرقابل انکار است [۲۷][۲۸]. اگر در گذشته، هوش مصنوعی صرفاً برای هدایت دشمنان استفاده می‌شد، امروزه تقریباً در تمام مراحل چرخه تولید بازی (از طراحی سطح و تولید گفت‌وگو تا تحلیل داده و پشتیبانی پس از انتشار) حضور دارد [۲۹].

تاریخچه کوتاه

نخستین گام‌های استفاده از هوش مصنوعی در بازی‌ها را می‌توان در Noughts and Crosses Machine (۱۹۵۲) مشاهده کرد [۳۰]. پس از آن در دهه ۹۰ میلادی، Dune II و Half-Life با معرفی سیستم‌های تصمیم‌گیری گروهی و مسیریابی پویا^۱ جهشی بزرگ ایجاد کردند [۳۱]. به همین ترتیب در دهه ۲۰۰۰، The Sims و F.E.A.R به ترتیب با شبیه‌سازی رفتار اجتماعی و هوش گروهی دشمنان مرزهای جدیدی را گشودند [۳۲]. و در نهایت از دهه ۲۰۱۰ به بعد، با ظهور یادگیری ماشین و یادگیری تقویتی،

ایجاد کند. الگوریتم‌های یادگیری ماشین، داده‌هایی مانند زمان بازی، دقت تیراندازی، الگوی حرکت و میزان موفقیت بازیکن را تحلیل می‌کنند. سپس بازی بر اساس این داده‌ها سطح دشواری، نوع مأموریت یا پیشنهادهای درون بازی را تنظیم می‌کند.

در (۲۰۰۸) Left ۴ Dead، سیستم "AI Director" شدت دشمنان را بر اساس عملکرد بازیکن تنظیم می‌کند [۴۴]. در بازی‌های موبایلی، AI زمان نمایش پاداش روزانه را با احتمال ریزش کاربر هماهنگ می‌سازد. نتیجتاً تجربه هر بازیکن منحصر به فرد است و وفاداری کاربر افزایش می‌یابد.

• تشخیص تقلب (Anti-Cheat Systems)

در بازی‌های آنلاین، تقلب یکی از بزرگ‌ترین تهدیدهاست. AI با تحلیل میلیون‌ها داده، رفتارهای مشکوک را شناسایی می‌کند. مدل‌های یادگیری ماشین داده‌هایی مانند سرعت واکنش، دقت تیراندازی و مسیر حرکت را مقایسه می‌کنند. اگر الگویی غیرطبیعی مشابه ربات شناسایی شود، سیستم هشدار می‌دهد یا حساب را مسدود می‌کند.

تکنیک‌های هوش مصنوعی در بازی‌ها

به‌عنوان نمونه در Valorant و Call of Duty: Warzone از مدل‌های یادگیری نظارت‌شده برای شناسایی چیت‌ها و بات‌ها استفاده می‌شود [۴۵].

• آزمون و کنترل کیفیت خودکار (Automated Testing & QA)

فرآیند تست بازی‌ها بسیار زمان‌بر است. AI می‌تواند به‌صورت خودکار هزاران سناریوی بازی را شبیه‌سازی و خطاها را شناسایی کند.

به‌عنوان یک نمونه واقعی Ubisoft با ابزار Commit Assistant و یادگیری ماشین، باگ‌ها را پیش‌بینی و رفع می‌کند [۴۶]. در شرکت EA نیز از شبیه‌سازهای AI برای آزمون خودکار مراحل بازی استفاده می‌شود.

• بهبود صدا و تصویر (Smart Audio & Visual Enhancement)

AI می‌تواند صدا و گرافیک را به‌صورت بلادرنگ بهینه کند. در صدا، شدت و تن موسیقی متناسب با موقعیت بازی تغییر می‌کند. در تصویر، AI برای بهبود بافت‌ها، نورپردازی و حذف نویزها استفاده می‌شود.

برای مثال در (۲۰۰۵) F.E.A.R، دشمنان از رفتار گروهی هوشمند استفاده می‌کنند؛ مثلاً دو نفر بازیکن را دور می‌زنند و سومی او را مشغول نگه می‌دارد [۳۹]. یا در The Last of Us Part II (۲۰۲۰)، دشمنان با نام یکدیگر را صدا می‌زنند و به مرگ هم‌تیمی‌ها واکنش احساسی نشان می‌دهند.

• تولید محتوای روبه‌ای (Procedural Content Generation)

یکی از پرکاربردترین حوزه‌های AI در بازی، تولید خودکار محتواست. الگوریتم‌های PCG می‌توانند نقشه، مرحله یا مأموریت را با حفظ تعادل بین سختی و پاداش تولید کنند [۴۰].

مثلاً در (۲۰۱۶) No Man's Sky، بیش از ۱۸ کوینتیلیون سیاره با الگوریتم‌های ترکیبی نوین پرلین و قواعد تولیدی ساخته شده‌اند [۴۱]. یا در (۲۰۱۱) Minecraft از ساختارهای لایه‌ای و نوین Simplex برای تولید زمین و بایوم استفاده می‌شود [۴۲]. در (۲۰۱۲) Diablo III نیز هر بار نقشه‌های بازی به‌صورت متفاوت و تصادفی تولید می‌شوند [۴۳]. که در نتیجه زمان توسعه کاهش می‌یابد و بازیکن هر بار با دنیایی تازه روبه‌رو می‌شود.



تصویر ۲: بازی ماینکرفت

• تحلیل داده و شخصی‌سازی تجربه بازیکن (Player Analytics & Personalization)

AI فقط در گیم‌پلی فعال نیست؛ بلکه داده‌های رفتاری بازیکن را نیز تحلیل می‌کند تا تجربه‌ای متناسب و متعادل

فناوری DLSS ۳.۵ شرکت NVIDIA وضوح تصویر را بدون افت عملکرد افزایش می‌دهد [۴۷]. در Cyberpunk ۲۰۷۷ (۲۰۲۰)، موسیقی و افکت‌ها با وضعیت صحنه همگام می‌شوند. این باعث می‌شود تجربه‌ای سینمایی‌تر و طبیعی‌تر برای بازیکن ایجاد شود.

• طراحی گفت‌وگو و صدای پیشگام (Dialogue & Voice AI)

مدل‌های زبانی بزرگ می‌توانند دیالوگ‌های طبیعی و پویا تولید کنند. مثلاً در پلتفرم Inworld AI امکان گفت‌وگوهای زنده با NPCها فراهم شده است [۴۸]. همچنین در بازی‌های مستقل جدید، از مدل‌های زبانی برای تولید گفت‌وگوهای شخصی‌شده استفاده می‌شود.

• پشتیبانی بازیکنان و تحلیل پس از انتشار (Post-Launch Analytics)

AI پس از عرضه بازی نیز نقش حیاتی دارد. الگوریتم‌ها داده‌های بازیکنان را برای تحلیل رفتار، کشف باگ‌ها و بهینه‌سازی توازن بازی بررسی می‌کنند. در Overwatch، Blizzard (۲۰۱۶) از تحلیل داده‌های مبتنی بر AI برای تنظیم تعادل قهرمان‌ها استفاده می‌کند [۴۹].

مزایا و چالش‌ها

مزایا شامل افزایش واقع‌گرایی، بهبود شخصی‌سازی، صرفه‌جویی در هزینه و ارتقای تجربه کاربر است. اما چالش‌هایی مانند وابستگی داده‌ای، اخلاق هوش مصنوعی و تهدید برای مشاغل خلاق نیز مطرح است [۵۰].


آینده هوش مصنوعی در بازی‌ها

سه روند اصلی آینده عبارت‌اند از:

۱. NPCهای آگاه احساسی [۵۱].
۲. طراحی بازی با پرامپت (Prompt-to-Game) [۵۲].
۳. روایت‌های مولد و تعاملی [۵۳].

نتیجه‌گیری

هوش مصنوعی امروز مغز متفکر صنعت بازی است. از خلق شخصیت‌های هوشمند تا روایت‌های پویا، از تحلیل رفتار بازیکن تا ساخت جهان‌های رویه‌ای، AI بنیان‌گذار عصر جدیدی از تجربه دیجیتال است.



نویسنده: فاطمه غیاث آبادی فراهانی

چرا این کتاب؟

- زبان ساده و روشن بدون قربانی کردن عمق علمی
- پوشش کامل چرخه یادگیری ماشین: از کار با داده‌های خام تا استقرار مدل در محیط واقعی.
- استفاده از ابزارهای استاندارد صنعت مثل Scikit-Learn، TensorFlow، و Keras.
- مناسب برای مبتدیانی که می‌خواهند اصول را درست یاد بگیرند و همچنین مهندسين و پژوهشگرانی که دنبال تکنیک‌های مدرن‌اند.

ویرایش سوم کتاب با افزودن بخش‌هایی درباره ترنسفورمرها، مدل‌های بینایی مدرن، Keras Tuner و مدل‌های مولد انتشار، آن را کاملاً به‌روز و هماهنگ با جریان فعلی هوش مصنوعی کرده است.

ساختار کتاب

این کتاب در دو بخش اصلی سازمان‌دهی شده است: «مبانی یادگیری ماشین» و «شبکه‌های عصبی و یادگیری عمیق».

• بخش اول؛ مبانی یادگیری ماشین

در این بخش، نویسنده با مثال‌های واقعی و یک پروژه End-to-End نشان می‌دهد که یک مدل یادگیری ماشین چگونه از دل داده‌ها شکل می‌گیرد. مباحثی مانند برازش مدل، گرادیان نزولی، پیش‌پردازش داده‌ها، مهندسی ویژگی، تنظیم ابرپارامترها و مقابله با بیش‌برازش (Overfitting) با زبانی قابل‌فهم و درعین‌حال دقیق معرفی شده‌اند.


الگوریتم‌های کلاسیک مانند رگرسیون، درخت تصمیم، Random Forest و روش‌های Ensemble نیز در این بخش جای دارند. فصل پایانی به یادگیری بدون ناظر و موضوعاتی مانند K-Means، PCA، و تشخیص ناهنجاری‌ها اختصاص یافته است.

• بخش دوم؛ شبکه‌های عصبی و یادگیری عمیق

این بخش نقشه راهی جامع برای ورود کاربردی به دنیای شبکه‌های عصبی ارائه می‌دهد. ابتدا ساختار نرون، الگوریتم پس انتشار و مبانی Keras و TensorFlow معرفی می‌شود. سپس مدل‌های گوناگون، از شبکه‌های کاملاً متصل گرفته تا CNN، RNN، LSTM، GRU و مدل‌های پیشرفته بینایی و پردازش زبان، مورد بررسی قرار می‌گیرند.

در دورانی که هوش مصنوعی با سرعتی چشمگیر مرزهای نوینی را درمی‌نوردد، یادگیری ماشین دیگر مهارتی جانبی محسوب نمی‌شود؛ بلکه بنیانی اساسی برای ورود به دنیای داده و فناوری به شمار می‌آید. در میان منابع متعدد این حوزه، کتاب «Hands-On Machine Learning» اثر «Aurélien Géron» جایگاهی ویژه دارد. این اثر از معدود آثاری است که توانسته میان سادگی بیان، دقت علمی و کاربرد عملی توازنی سنجیده برقرار کند.

نویسنده مخاطب را گام‌به‌گام همراهی می‌کند؛ از مفاهیم پایه‌ای مانند رگرسیون و دسته‌بندی آغاز کرده و تا معماری‌های پیشرفته شبکه‌های عصبی، ترنسفورمرها، مدل‌های مولد GAN و Diffusion و یادگیری توزیع‌شده با TensorFlow پیش می‌رود. آنچه این کتاب را از سایر منابع متمایز می‌سازد، رویکرد واقع‌گرایانه و پروژه‌محور آن است؛ به‌گونه‌ای که هر فصل ترکیبی از توضیحی روشن، مثال‌های عملی و کدهای دقیق ارائه می‌دهد و سبب می‌شود مفاهیم نه‌تنها درک، بلکه به‌صورت عمیق تجربه شوند.



تصویر ۱: کتاب Hands-On Machine Learning

واژه‌نامه

- Scikit-Learn: کتابخانه‌ای در پایتون برای پیاده‌سازی الگوریتم‌های کلاسیک یادگیری ماشین؛ ساده، پرکاربرد و از استانداردهای رایج در صنعت.
- TensorFlow: چارچوبی قدرتمند برای یادگیری ماشین که توسط Google توسعه یافته و برای ساخت و اجرای مدل‌های یادگیری عمیق در مقیاس بزرگ به کار می‌رود.
- Keras: رابط سطح بالای TensorFlow برای ساخت مدل‌های شبکه عصبی با کدنویسی ساده‌تر و سریع‌تر.
- End-to-End Project (پروژه سراسری): پروژه‌ای که تمامی مراحل را در بر می‌گیرد؛ از جمع‌آوری داده تا آموزش، ارزیابی و استقرار مدل.
- Gradient Descent (گرادیان نزولی): الگوریتمی برای کمینه‌سازی تابع هزینه از طریق حرکت در جهت شیب منفی.
- Overfitting (بیش برارزش): وضعیتی که در آن مدل بیش از حد به داده‌های آموزشی وابسته می‌شود و در مواجهه با داده‌های جدید عملکرد ضعیفی دارد.
- Hyperparameters (ابریارامتها): تنظیمات بیرونی مدل، مانند نرخ یادگیری یا تعداد لایه‌ها که پیش از فرایند آموزش تعیین می‌شوند.
- CNN – Convolutional Neural Network (شبکه عصبی پیچشی): نوعی شبکه عصبی که عمدتاً در بینایی ماشین و پردازش تصویر کاربرد دارد.
- RNN – Recurrent Neural Network (شبکه عصبی بازگشتی): نوعی شبکه عصبی مناسب برای داده‌های ترتیبی، مانند متن و سری‌های زمانی.
- Transformer (ترنسفورمر): معماری مدرن شبکه‌های عصبی مبتنی بر سازوکار «توجه» که زیربنای مدل‌هایی مانند BERT و GPT است.
- GAN – Generative Adversarial Network (شبکه مولد تخاصمی): معماری‌ای متشکل از دو شبکه رقابتی برای تولید داده‌های شبیه‌سازی‌شده، مانند تصاویر مصنوعی.
- Diffusion Models (مدل‌های انتشار): دسته‌ای از مدل‌های مولد که با حذف تدریجی نویز، داده‌های جدید با کیفیت بالا تولید می‌کنند.
- TensorFlow Serving: ابزاری برای استقرار مدل‌های TensorFlow در محیط‌های عملیاتی و ارائه پاسخ با سرعت بالا.
- Decision Tree (درخت تصمیم): الگوریتمی ساده و قابل تفسیر که داده‌ها را بر اساس پرسش‌های شرطی به شاخه‌های گوناگون تقسیم می‌کند تا به یک پیش‌بینی برسد.
- Random Forest (جنگل تصادفی): یک روش Ensemble که مجموعه‌ای از درخت‌های تصمیم را می‌سازد و با ترکیب نتایج آن‌ها به دقت بالاتر و پایداری بیشتر می‌رسد.
- Ensemble Methods (روش‌های تلفیقی / مجموعه‌ای): تکنیک‌هایی که چند مدل را با هم ترکیب می‌کنند تا عملکرد نهایی بهتر از مدل‌های منفرد شود (مثل Random Forest و Gradient Boosting).
- PCA – Principal Component Analysis (تحلیل مؤلفه‌های اصلی): روش کاهش ابعاد که ویژگی‌های مهم‌تر داده را استخراج می‌کند و بدون ازدست‌دادن اطلاعات اصلی، داده را فشرده‌تر می‌سازد.
- K-Means (کی - مینز): الگوریتم خوشه‌بندی که داده‌ها را بر اساس شباهت، به k دسته تقسیم می‌کند و مرکز هر دسته را «میانگین» داده‌های آن تعیین می‌کند.
- LSTM – Long Short-Term Memory (شبکه حافظه بلند - کوتاه‌مدت): نوعی شبکه بازگشتی (RNN) که می‌تواند وابستگی‌های بلندمدت در داده‌های ترتیبی مانند متن یا سری زمانی را بهتر حفظ کند.
- GRU – Gated Recurrent Unit (واحد بازگشتی دروازه‌دار): نسخه ساده‌تر و سریع‌تر LSTM که با تعداد پارامتر کمتر، معمولاً عملکردی مشابه ارائه می‌دهد.

فصل‌های پایانی نیز به موضوعات پیشرفته‌ای مانند GAN ها، مدل‌های انتشار، یادگیری تقویتی عمیق و در نهایت استقرار مدل‌ها در محیط‌های حرفه‌ای (از جمله TensorFlow Serving، سرویس‌های ابری و حتی مرورگر) اختصاص یافته است.



اولین ژرون یک مشاور حوزه یادگیری ماشین است. او که سابقه کار در گوگل را دارد، از سال ۲۰۱۳ تا ۲۰۱۶ رهبری تیم طبقه‌بندی ویدئو در یوتیوب را بر عهده داشت. همچنین بین سال‌های ۲۰۰۲ تا ۲۰۱۲ یکی از بنیان‌گذاران و مدیر فنی (CTO) شرکت Wifirst بود؛ یکی از ارائه‌دهندگان بزرگ اینترنت بی‌سیم در فرانسه. او در سال ۲۰۰۱ نیز یکی از بنیان‌گذاران و مدیر فنی شرکت Polyconseil، یک شرکت مشاوره در حوزه مخابرات، بود.

پیش از این‌ها، او به عنوان مهندس در حوزه‌های مختلفی فعالیت کرده است: امور مالی (در JP Morgan و Société Générale)، دفاعی (وزارت دفاع کانادا) و حوزه سلامت (انتقال خون). او چند کتاب فنی (درباره C++، وای‌فای و معماری‌های اینترنت) منتشر کرده و در یک مدرسه مهندسی در فرانسه نیز مدرس علوم کامپیوتر بوده است.

جمع‌بندی

اگر به دنبال منبعی هستید که افزون بر آموزش مفاهیم، شما را به سمت طراحی و اجرای پروژه‌های واقعی هدایت کند، کتاب Hands-On Machine Learning انتخابی کم‌نظیر است. این اثر پلی میان دانش نظری و مهارت عملی ایجاد می‌کند؛ هم برای دانشجویانی که به‌تازگی مسیر هوش مصنوعی را آغاز کرده‌اند و هم برای افرادی که قصد دارند بر مدل‌های پیشرفته و ابزارهای روز تسلط یابند.

• اجتماع مجموعه‌ها: اجتماع تعداد متناهی از مجموعه‌های متناهی، متناهی است. همچنین، اجتماع یک کلکسیون شمارش‌پذیر از مجموعه‌های شمارش‌پذیر، همچنان شمارش‌پذیر باقی می‌ماند.

• حفظ کاردینالیته: اگر بین دو مجموعه A و B یک نگاشت یک‌به‌یک برقرار باشد، آن‌ها کاردینالیته یکسانی دارند. اگر A نامتناهی باشد، B نیز نامتناهی خواهد بود.

روابط همسایگی

در نظریه مجموعه‌های خشن (Rough Sets) که جلوتر به آن اشاره می‌کنیم، روابط همسایگی ابزاری برای گروه‌بندی اعضای هستند که به دلیل نقص اطلاعات، «شبهه» یا «مرتبط» با یکدیگر به نظر می‌رسند [۵۵]. این روابط به ما کمک می‌کنند تا در دنیای داده‌های نامطمئن، مرزهای دقیق‌تری برای خوشه‌بندی و تصمیم‌گیری ایجاد کنیم.

روابط همسایگی به دسته‌های پایه، متعددی و همسایگی در فضای فازی (که با فضای فازی نیز آشنا می‌شویم) تقسیم‌بندی می‌شوند [۵۵]. همسایگی ابزاری برای دسته‌بندی و گروه‌بندی عناصری است که بر اساس یک رابطه باینری یا همان بودن-نبودن (مانند رابطه شباهت یا هم‌ارزی) با یکدیگر در ارتباط هستند. این مفهوم به ما کمک می‌کند تا در شرایطی که اطلاعات ناقص یا نامطمئن داریم، مرزهای بین داده‌ها را مشخص کنیم.

نظریه مجموعه‌های خشن (Rough Sets)

این نظریه اولین بار توسط زدیسلو پاولاک (Zdzisław Pawlak) در سال ۱۹۸۲ معرفی شد و یک رویکرد ریاضی برای مواجهه با اطلاعات ناقص، مبهم و غیرقطعی در فرآیند طبقه‌بندی داده‌ها و کشف دانش است [۵۶]. برخلاف نظریه مجموعه‌های کلاسیک که عضویت در آن به صورت قطعی یا همان باینری (هست یا نیست) تعریف می‌شود، این نظریه بر مبنای مفهوم «تقریب (Approximation)» استوار است.

سنگ‌بنای مجموعه‌های خشن، رابطه هم‌ارزی (Equivalence Relation) است [۵۶]. این رابطه عناصر را به گروه‌هایی به نام «کلاس‌های هم‌ارزی» تقسیم می‌کند. عناصری که در یک کلاس قرار می‌گیرند، با توجه به اطلاعات موجود، «تشخیص‌ناپذیر» هستند؛ یعنی دانش فعلی ما اجازه نمی‌دهد بین آن‌ها تفاوتی قائل شویم.

در مقاله پیش‌رو، مجموعه‌ای از مفاهیم وجود دارد که ممکن است برای ما جدید باشد. برای آسودگی در روند خواندن مقاله، مفاهیمی که به نظر می‌رسید تخصصی رشته هوش مصنوعی باشند را به صورت تعاریفی روان و ساده آماده کرده‌ایم تا بتوانیم مطالب مقاله را راحت‌تر بررسی کنیم. در ادامه، ابتدا به تعریف مفاهیم جدید در مجموعه‌ها می‌پردازیم؛ سپس به سراغ مفاهیم عدم قطعیت و اطلاعات می‌رویم و در آخر، مفاهیم الگوریتمی جدید را بررسی می‌کنیم.

کاردینالیته (Cardinality)

در ریاضی با مفهومی به نام مجموعه (Set) آشنا هستیم که گروهی از عناصر هستند که هیچ دو عضو تکراری در یک مجموعه وجود ندارد و همه عناصر از هم متمایز هستند. در نظریه مجموعه‌ها، کاردینالیته یک مجموعه به معنای اندازه‌گیری تعداد اعضا یا همان اندازه مجموعه است [۵۴]. این مفهوم در مجموعه‌ها به ما قابلیت مقایسه بزرگی دو مجموعه را می‌دهد، خواه متناهی باشند یا نامتناهی.

در مجموعه‌های متناهی، در تعریف ریاضی از تناظر یک‌به‌یک اعضای مجموعه با اعداد متوالی از ۱ تا n برای به دست آوردن کاردینالیته مجموعه استفاده می‌شود. روش راحت‌تر، شمارش اعضاست که خود به نوعی ایجاد یک تناظر یک‌به‌یک است، ولی تا حد زیادی کار را برای به دست آوردن کاردینالیته مجموعه ساده می‌کند.

کاردینالیته در مجموعه‌های نامتناهی به دو دسته شمارش‌پذیر و ناشمارا تقسیم‌بندی می‌شود که از حوصله این بحث خارج است و نیازی به آن نداریم؛ ولی اگر علاقه‌مند هستید، می‌توانید مقالات مربوط به تعاریف آن را مطالعه کنید.

همچنین در خود کاردینالیته مفاهیمی وجود دارد که در ادامه به آن‌ها اشاره می‌کنم:

مفهوم زیرمجموعه و ابرمجموعه:

هر زیرمجموعه از یک مجموعه متناهی، متناهی است؛ در مقابل، هر ابرمجموعه از یک مجموعه نامتناهی، قطعاً نامتناهی خواهد بود.

آنتروپی شانون

این تعریف که توسط کلود شانون معرفی شد، آنتروپی را به‌عنوان «مقدار اطلاعات» یا ابهام موجود در یک توزیع احتمالی تعریف می‌کند. آنتروپی شانون نشان‌دهنده میانگین حداقل تعداد پرسش‌های بله/خیر (بیت‌ها) است که برای شناسایی یک نتیجه پنهان نیاز داریم [۵۸][۵۹].

آنتروپی شانون مانند «تعداد خانه‌های خالی در یک جدول کلمات» است. وقتی هیچ خانه‌ای پر نشده باشد، آنتروپی حداکثر است؛ زیرا درباره کلمات نهایی ابهام زیادی دارید. هر حرفی که به‌درستی در جدول قرار می‌دهید (کسب اطلاعات)، باعث کاهش آنتروپی می‌شود. آنتروپی شانون به شما می‌گوید به‌طور متوسط به چند حرف (بیت) نیاز دارید تا کل جدول را حل کنید؛ در حالی که آنتروپی منطقی احتمال این را می‌سنجد که اگر دو خانه تصادفی را نگاه کنید، حروف آن‌ها با هم متفاوت باشند.

آنتروپی منطقی

آنتروپی منطقی برابر است با احتمال این‌که در دو نمونه‌برداری مستقل، دو نتیجه متفاوت حاصل شود. در حالی که شانون لایه‌های تقسیم‌بندی (بیت‌ها) را می‌شمارد، آنتروپی منطقی مستقیماً میزان تفاوت‌ها و تنوع را مقداردهی می‌کند [۵۸].

آنتروپی مشروط

آنتروپی مشروط، میانگین میزان اطلاعاتی است که برای توصیف کامل متغیر Y نیاز داریم، به شرطی که قبلاً از وضعیت متغیر X آگاه شده باشیم. این شاخص در واقع «میزان جهل باقی‌مانده» درباره Y را پس از کسب دانش درباره X اندازه‌گیری می‌کند [۵۹]. (مثلاً چند خانه از یک کلمه دیگر را باید کامل کنیم اگر کلمه فعلی را حدس بزنیم.)

آنتروپی یگر

آنتروپی یگر (Yager's Entropy) که به‌عنوان «معیار فازی بودن» نیز شناخته می‌شود، ابزاری ریاضی برای اندازه‌گیری میزان ابهام و فازی بودن در یک مجموعه داده است. ایده اصلی یگر این است که عدم قطعیت در یک مجموعه فازی ناشی از عدم تمایز کافی بین آن مجموعه و مکمل (نقیض) آن است [۶۰][۶۱]. (در ادامه به مفهوم فازی بودن اشاره می‌شود؛ این قسمت را بعد از خواندن مفهوم منطق فازی نیز بررسی می‌کنیم.)

هر مجموعه هدف (A) در این فضا به کمک دو مرز توصیف می‌شود:

۱. تقریب پایین: $(P(A))$ شامل تمام کلاس‌هایی است که به‌طور کامل درون مجموعه هدف قرار می‌گیرند. این‌ها اعضای هستند که با اطمینان کامل می‌توان گفت متعلق به مجموعه A هستند [۵۶].

۲. تقریب بالا: شامل کلاس‌هایی است که حداقل یک عضو مشترک با مجموعه هدف دارند. این‌ها اعضای هستند که احتمالاً متعلق به مجموعه A هستند [۵۶].

ناحیه مرزی: (Boundary Region) اختلاف بین تقریب بالا و پایین است. به زبان ساده، این ناحیه شامل عناصری است که با توجه به اطلاعات موجود، نمی‌توان با قطعیت گفت که متعلق به مجموعه مورد نظر هستند یا نه؛ یعنی اعضای که در تقریب بالا هستند؛ اما در تقریب پایین نیستند [۵۶].

خشن بودن یک مجموعه به این بستگی دارد که آیا عنصری در ناحیه مرزی وجود دارد یا نه. اگر وجود داشته باشد، این مجموعه را خشن می‌نامیم.

شاخص دقت (a) نسبت تعداد اعضای تقریب پایین به تقریب بالا است. هرچه این عدد به ۱ نزدیک‌تر باشد، دقت طبقه‌بندی بالاتر و خشن بودن مجموعه کمتر است [۵۶].

همچنین مدل‌های دیگر و پیشرفته‌تری در این سرفصل قرار دارند، مانند روابط همسایگی که یکی از مدل‌های پیشرفته همین حوزه است. مجموعه‌های خشن فازی و همسایگی‌های متعددی نیز مطرح می‌شوند. مجموعه‌های خشن کاربرد مستقیم در هوش مصنوعی دارند و پیشنهاد می‌شود این سرفصل را به‌صورت کامل مطالعه کنید.

آنتروپی (Entropy) و انواع آن

آنتروپی (Entropy) در یک تعریف جامع، معیاری ریاضی [۵۸] برای اندازه‌گیری میزان عدم قطعیت (Uncertainty)، بی‌نظمی یا ابهام در یک سیستم، توزیع احتمالی یا مجموعه‌ای از داده‌ها است. در ریاضیات، چند تعریف برای آنتروپی وجود دارد که به برخی از آن‌ها در ادامه اشاره می‌کنیم.

در حوزه‌هایی مانند مجموعه‌های خشن و منطق فازی، آنتروپی برای اندازه‌گیری خشن بودن و ابهام در گروه‌های داده‌ای مشابه به کار می‌رود. آنتروپی کمتر نشان‌دهنده اطلاعات دقیق‌تر سیستم است. در داده‌کاوی، از آنتروپی شرطی برای شناسایی ویژگی‌های مهم استفاده می‌شود؛ هر ویژگی که آنتروپی (ابهام) طبقه تصمیم‌گیری را بیشتر کاهش دهد، بارزتر است.

برای مثال، یک راننده برای ترمز گرفتن، به جای محاسبه دقیق فاصله بر حسب متر، از مفاهیمی مثل «نزدیک بودن» چراغ استفاده می‌کند.

تابع عضویت (f_A) تابعی است که هر نقطه از فضای داده را به عددی بین ۰ و ۱ نگاشت می‌کند. عملگرهای منطقی کلاسیک در اینجا بازتعریف می‌شوند. برای مثال، عملگر اشتراک (AND) معمولاً با تابع MIN (حداقل) و عملگر اجتماع (OR) با تابع MAX (حداکثر) محاسبه می‌شود.

در این منطق، برای رسیدن به جواب مسئله، چهار مرحله را باید طی کنیم: ابتدا فازی‌سازی مسئله؛ ورودی‌های دقیق (مثلاً عدد دمای ۲۵ درجه) را به درجات عضویت فازی تبدیل می‌کنیم. سپس با استفاده از عملگرهای منطقی فازی، نتایج قوانین را ترکیب می‌کنیم و در نهایت، در بخش «نافازی‌سازی»، جواب فازی را به اعداد دقیق نگاشت می‌کنیم [۶۴].

۲. همسایگی فازی

در فضای منطق فازی، همسایگی مانند یک اتاق با دیوارهای صلب نیست که شما یا درون آن باشید یا بیرون؛ بلکه بیشتر شبیه به یک هاله یا ابر است که هرچه به مرکز آن نزدیک‌تر شوید، حضور شما پررنگ‌تر (درجه عضویت بالاتر) و هرچه دورتر شوید، این حضور کم‌رنگ‌تر می‌شود [۵۷].

در فضای فازی، معیار همسایه بودن «تابع شباهت» است. در یک مثال ساده، تابع شباهت در اعداد، میزان نزدیک بودن یک عدد به عدد مدنظر ما را نشان می‌دهد. این مدل همسایگی به ما اجازه می‌دهد «مجموعه‌های خشن فازی» را بسازیم. کاربرد این مجموعه‌ها در طبقه‌بندی داده‌های واقعی و موارد دیگر است.

۳. آنتروپی یگر (Yager's Entropy)

آنتروپی یگر که به آن «معیار فازی بودن» نیز گفته می‌شود، ابزاری برای اندازه‌گیری میزان ابهام و عدم قطعیت در مجموعه‌های فازی است [۶۱]. برخلاف آنتروپی کلاسیک که بر پایه احتمالات است، یگر آنتروپی را بر اساس عدم تمایز بین یک مجموعه و مکمل (نقیض) آن تعریف می‌کند.

آنتروپی یگر بر پایه درجه ابهام (Fuzziness) است. به عبارت دیگر، شانون به ما می‌گوید چقدر «اطلاعات» کم داریم، اما یگر به ما می‌گوید چقدر داده‌های ما «کدر و مبهم» هستند [۶۰][۶۱].

اطلاعات متقابل

اطلاعات متقابل میزان وابستگی یا اطلاعات مشترک بین دو متغیر تصادفی را اندازه‌گیری می‌کند. به عبارت ساده، این معیار نشان می‌دهد که با دانستن یکی از متغیرها، چه مقدار از عدم قطعیت (آنتروپی) درباره متغیر دیگر کاسته می‌شود [۶۲].

در نظریه شانون، اطلاعات متقابل برابر است با تفاوت بین آنتروپی کل یک متغیر و آنتروپی مشروط آن. اگر دو متغیر کاملاً مستقل باشند، اطلاعات متقابل آن‌ها صفر است. همچنین اطلاعات متقابل را در منطق فازی نیز بررسی می‌کنیم.

منطق فازی

در ادامه به بخش مهم منطق فازی می‌رسیم. بیشتر مواردی که گفتیم در منطق بولی (بودن کامل یا نبودن کامل) بودند. منطق فازی (Fuzzy Logic) تعمیمی از منطق کلاسیک (Boolean) است که در سال ۱۹۶۵ توسط لطفی‌زاده (لطفی علی‌عسگرزاده - Lotfi Aliaskerzade) معرفی شد. برخلاف منطق سنتی که در آن هر گزاره تنها می‌تواند «درست» یا «نادرست» (۰ یا ۱) باشد، منطق فازی مفهوم «درجه عضویت» را معرفی می‌کند؛ به این معنا که یک شرط می‌تواند در وضعیت بین کاملاً درست و کاملاً نادرست قرار بگیرد [۶۳].

توجه داشته باشید که منطق مجموعه‌های خشن، فازی نبود و مجموعه‌های خشن در منطق بولی هستند. در منطق فازی، ما مجموعه‌های فازی را داریم.

۱. مجموعه فازی

در منطق فازی، یک عضو می‌تواند به میزان $0/8$ به یک مجموعه تعلق داشته باشد. این رویکرد به سیستم‌ها اجازه می‌دهد تا با ابهام و عدم قطعیت موجود در دنیای واقعی و زبان طبیعی، بسیار منعطف‌تر برخورد کنند [۶۳].

یکی از بزرگ‌ترین مزایای منطق فازی، فرمول‌بندی استدلال‌های انسانی به زبان طبیعی است. در این سیستم، به جای استفاده از اعداد دقیق، از متغیرهای زبانی مانند «کیفیت خوب»، «سرعت بالا» یا «دمای متوسط» استفاده می‌شود.

۴. اطلاعات متقابل در منطق فازی

در مجموعه‌های فازی، چون به‌جای احتمال با درجه عضویت سروکار داریم، اطلاعات متقابل معمولاً به‌صورت فازی تعریف می‌شود. در سیستم‌های اطلاعاتی فازی، اطلاعات متقابل برای سنجش اهمیت ویژگی‌ها به کار می‌رود. اگر با اضافه کردن یک ویژگی جدید به سیستم، اطلاعات متقابل بین ویژگی‌ها و طبقه تصمیم‌گیری (Decision Class) افزایش یابد، یعنی آن ویژگی اطلاعات ارزشمندی برای دسته‌بندی دقیق‌تر داده‌ها فراهم کرده است [۶۲].

اطلاعات متقابل همیشه نشان‌دهنده این است که دانستن یک متغیر، ابهام ما را درباره دیگری کاهش می‌دهد یا در بدترین حالت، تغییری ایجاد نمی‌کند. کاربرد اصلی این مبحث در انتخاب ویژگی است. یکی از مهم‌ترین کاربردهای اطلاعات متقابل در منطق فازی، حذف داده‌های اضافی و تکراری است. ویژگی‌هایی انتخاب می‌شوند که بیشترین اطلاعات متقابل را با هدف داشته باشند [۶۲].

الگوریتم‌های حریصانه

الگوریتم‌های حریصانه (Greedy Algorithms) دسته‌ای از الگوریتم‌های ریاضی و علوم کامپیوتر هستند که بر پایه یک منطق ساده بنا شده‌اند: «در هر مرحله، بهترین گزینه موجود در همان لحظه را انتخاب کن، به امید این‌که در نهایت به بهترین راه‌حل کل مسئله برسیم» [۶۵].

الگوریتم‌های حریصانه به‌صورت مرحله‌به‌مرحله (Iterative) عمل می‌کنند. در هر مرحله، الگوریتم گزینه‌ای را انتخاب می‌کند که بیشترین سود یا کمترین هزینه را در همان لحظه دارد (در اصطلاح به آن بهینه محلی می‌گوییم)، بدون این‌که نگران باشد این انتخاب در مراحل بعدی چه تأثیری بر نتیجه کل خواهد داشت [۶۵].

بسیاری از مسائل در دنیای واقعی به‌قدری پیچیده و زمان‌گیر هستند (مسائل NP-hard) که پیدا کردن راه‌حل دقیق و ۱۰۰٪ کامل (الگوریتم‌های پویا یا سایر الگوریتم‌هایی که مطمئن هستیم جواب بهینه می‌دهند) برای آن‌ها ممکن است قرن‌ها طول بکشد. در چنین مواردی، الگوریتم‌های حریصانه به دلیل سرعت بالا و سادگی در اجرا، راه‌حل‌های «تقریبی» بسیار خوبی ارائه می‌دهند که برای کاربردهای عملی کافی هستند؛ ولی عیب بزرگ آن‌ها این است که همیشه به بهترین جواب نهایی نمی‌رسند.

الگوریتم‌های اکتشافی

الگوریتم‌های اکتشافی (Heuristic Algorithms) ابزارهایی در علوم کامپیوتر و ریاضیات هستند که برای حل مسائل بسیار پیچیده طراحی شده‌اند؛ مسائلی که الگوریتم‌های دقیق (Exact) برای یافتن پاسخ آن‌ها ممکن است به قرن‌ها زمان نیاز داشته باشند. این الگوریتم‌ها به‌جای تمرکز بر یافتن پاسخ «دقیق و ۱۰۰٪ درست»، بر یافتن یک پاسخ تقریبی و «به‌اندازه کافی خوب» در زمان و فضای محاسباتی معقول تمرکز می‌کنند [۶۶].

مقدمه مقاله

هرچه آنتروپی شرطی یک زیرمجموعه ویژگی نسبت به ویژگی تصمیم^۶، کمتر باشد، توانایی آن زیرمجموعه در تمیز بین نمونه‌های با تصمیم‌های متفاوت، بیشتر است. آنتروپی نقش مهمی در شناسایی الگو و انتخاب ویژگی ایفا کرده است. از زمانی که شانون^۷ برای نخستین بار آنتروپی اطلاعات را برای ارزیابی عدم قطعیت در فضاهای گسسته نمونه‌ها معرفی کرد، این مفهوم در حوزه‌های گوناگونی به کار گرفته شده است. بسط‌هایی از آنتروپی و گونه‌های متنوع آن نیز در انتخاب ویژگی مورد استفاده قرار گرفته‌اند. برای محاسبه اطلاعات تمیز کننده ویژگی‌های فازی یا عددی، یگر^۸ مفهوم آنتروپی را در روابط شباهت فازی به کار برد. در واقع، آنتروپی یگر تعمیمی از آنتروپی شانون است و بر پایه کلاس‌های هم‌ارزی یا کلاس‌های شباهت فازی^۹ تعریف می‌شود.

در سال ۲۰۰۲، هرناندز^{۱۰} و رسنس^{۱۱} کار یگر را گسترش دادند و فرمول‌های آنتروپی مشترک و آنتروپی شرطی را بر اساس آنتروپی یگر ارائه کردند، سپس از این معیارها برای یادگیری درختان تصمیم فازی^{۱۲} از مجموعه‌ای از نمونه‌های داده استفاده نمودند. هو^{۱۳} و همکاران با الهام از کار یگر، آنتروپی مشترک و شرطی را دوباره تعریف کردند و از آن‌ها برای سنجش عدم قطعیت توانایی تمیز یک مجموعه از روابط شباهت فازی بهره بردند. در سال ۲۰۰۵، می^{۱۴} و همکاران معیاری برای تمیزپذیری رابطه هم‌ارزی فازی^{۱۵} بر پایه مدل مجموعه خشن فازی^{۱۶} معرفی کردند. در سال ۲۰۰۸، چیان^{۱۷} و لیانگ^{۱۸} معیاری ترکیبی برای ارزیابی عدم قطعیت توانایی تمیز یک زیرمجموعه از ویژگی‌ها پیشنهاد دادند. در سال ۲۰۱۱، هو و همکاران مفاهیم آنتروپی همسایگی، آنتروپی شرطی همسایگی و اطلاعات متقابل همسایگی را در فضاهای عددی برای ارزیابی ارتباط میان ویژگی‌های پیوسته و ویژگی‌های تصمیم گسسته معرفی کردند. همه این مطالعات حول محور گسترش آنتروپی شانون یا آنتروپی یگر و کاربردهای آن‌ها بوده‌اند.

با پیشرفت فناوری رایانه و پایگاه داده، حجم داده‌ها به صورت نمایی در حال رشد است. در ایده‌آل‌ترین حالت، اطلاعات ارائه شده سودمند هستند؛ با این حال، داده‌ها اغلب حاوی اطلاعات اضافی و تکراری هستند. بنابراین، پیش از به‌کارگیری یک مجموعه داده، ضروری است که از طریق پیش‌پردازش، ویژگی‌های زائد حذف شوند. انتخاب ویژگی یکی از ابزارهای مهم برای کاهش این افزونگی است. بیشتر پژوهشگران درصد هستند تا با استفاده از انتخاب ویژگی، با داده‌های با ابعاد بالا سروکار داشته باشند. هدف این است که زیرمجموعه‌ای از ویژگی‌ها را بر اساس معیارهای ارزیابی، به گونه‌ای انتخاب کنیم که بیشترین توان طبقه‌بندی را داشته باشد، و بدین‌سان بتوانیم ویژگی‌های کلیدی داده‌های با ابعاد بالا را با تحلیل نسخه‌ی با ابعاد کم آن‌ها استخراج کنیم. انتخاب ویژگی یک تکنیک مؤثر برای ساده‌سازی تحلیل داده و کشف ویژگی‌های اصلی آن محسوب می‌شود. امروزه این موضوع توجه زیادی را در حوزه‌های شناسایی الگو، یادگیری ماشین، و داده‌کاوی به خود جلب کرده است.

روابطی که توسط یک زیرمجموعه از ویژگی‌ها ایجاد می‌شوند، شباهت یا عدم شباهت میان نمونه‌ها را نشان می‌دهند. نمونه‌های مشابه، یک کلاس شباهت را تشکیل می‌دهند، درحالی‌که نمونه‌های نامشابه در کلاس‌های جداگانه قرار می‌گیرند. چنین روابطی می‌توانند توانایی ویژگی‌ها را در تمیز بین نمونه‌ها نشان دهند. از این روابط تاکنون برای گسسته‌سازی داده‌های عددی^۱، خوشه‌بندی^۲، کاهش ویژگی^۳، و استدلال در شرایط عدم قطعیت و تصمیم‌گیری^۴ استفاده شده است. روابط هم‌ارزی، روابط شباهت، روابط همسایگی، و روابط غلبه، پایه‌های مدل‌های مختلفی از مجموعه‌های خشن^۵ هستند.

آنتروپی به‌عنوان یک معیار عدم قطعیت، ابزاری مؤثر برای سنجش اطلاعات تمیز کننده یک زیرمجموعه از ویژگی‌هاست.

Qian .۱۷

Liang .۱۸

Fuzzy similarity .۹

Hernandez .۱۰

Recasens .۱۱

Fuzzy decision trees .۱۲

Hu .۱۳

Mi .۱۴

Fuzzy equivalence relations .۱۵

Fuzzy Rough Set .۱۶

Discretization of numerical data .۱

Clustering .۲

Feature reduction .۳

Reasoning under uncertainty and decision-making .۴

Rough Sets .۵

decision attribute .۶

Shannon .۷

Yager .۸

آنتروپی یگر بنا شده‌اند، این روش نیازی به تبدیل داده‌های عددی به فرم گسسته یا ساخت کلاس‌های شباهت فازی ندارد. به‌جای آن، نویسندگان شاخص تمایز همسایگی را معرفی می‌کنند؛ معیاری که مستقیماً از رابطه همسایگی بین نمونه‌ها استفاده کرده و تنها با شمارش تعداد جفت‌هایی که در یک همسایگی قرار می‌گیرند، یعنی کاردینالیته رابطه همسایگی، محاسبه می‌شود. این رویکرد نه‌تنها ساده‌تر است، بلکه از نظر محاسباتی نیز کارآمدتر عمل می‌کند.

برای تحلیل جامع‌تر، سه نوع از این شاخص تعریف شده است: تمایز مشترک برای سنجش توان تمایز ترکیب دو گروه ویژگی، تمایز شرطی برای اندازه‌گیری میزان ابهام باقی‌مانده پس از دانستن یک زیرمجموعه، و تمایز متقابل که نشان می‌دهد چقدر یک زیرمجموعه در پیش‌بینی برچسب کلاس مفید است. این سه معیار از نظر رفتاری مشابه آنتروپی شانون و مشتقات آن هستند، اما برخلاف آن‌ها، به ساخت ساختارهای پیچیده‌ای؛ مانند کلاس‌های همسایگی وابسته نیستند. برای کار با داده‌های عددی، پارامتری به نام شعاع همسایگی معرفی شده است که آستانه‌ای برای تشخیص اینکه دو نمونه چقدر به هم نزدیک هستند، در نظر گرفته می‌شود. اگر بیشترین اختلاف دو نمونه در هر یک از ویژگی‌ها از این آستانه کمتر باشد، آن دو نمونه غیرقابل‌تمایز در نظر گرفته می‌شوند. این پارامتر انعطاف‌پذیری لازم را فراهم می‌آورد تا بتوان روش را برای انواع داده‌های واقعی تنظیم کرد، بدون اینکه نیازی به گسسته‌سازی مصنوعی باشد.

بر اساس این چارچوب، الگوریتمی به نام $HANDI^1$ طراحی شده است که یک الگوریتم حریصانه است. این الگوریتم در هر مرحله، ویژگی‌ای را انتخاب می‌کند که بیشترین کاهش را در شاخص تمایز شرطی تصمیم ایجاد کند. این کاهش به‌عنوان اهمیت ویژگی در نظر گرفته می‌شود و معیاری برای شناسایی ویژگی‌های زائد فراهم می‌آورد. آزمایش‌ها روی سیزده مجموعه داده استاندارد از منابع عمومی نشان می‌دهد که روش پیشنهادی در مقایسه با چهار روش پیشرفته رقیب، شامل NRS^2 ، $NEIEN^3$ ، $FINEN^4$ و $FRSINT^5$ ، عملکرد بهتری دارد. $HANDI$ در اکثر موارد

همسایگی یکی از مهم‌ترین مفاهیم در یادگیری طبقه‌بندی است. همسایگی می‌تواند برای تولید کلاس‌های شباهت از نمونه‌هایی که توسط ویژگی‌های عددی توصیف شده‌اند، و همچنین برای تمیز بین نمونه‌ها به کار رود. اطلاعات تمیزکننده یک زیرمجموعه ویژگی به روابط همسایگی تولیدشده توسط آن زیرمجموعه وابسته است. در این مقاله، ما معیاری جدید برای اطلاعات تمیزکننده بنام شاخص تمایز همسایگی را مبتنی بر روابط همسایگی پیشنهاد می‌کنیم. این شاخص در مقایسه با آنتروپی یگر و گونه‌های آن، خاصیت‌هایی شبیه به آنتروپی شانون دارد، اما مستقیماً بر پایه روابط همسایگی تعریف شده و با محاسبه کاردینالیته (تعداد اعضای) رابطه همسایگی، نه کلاس‌های شباهت همسایگی، به دست می‌آید. از این رو، پیچیدگی محاسباتی شاخص تمایز پیشنهادی کمتر است.

ما شاخص‌های تمایز مشترک، شرطی، و متقابل را تعریف کرده و خواص پایه آن‌ها را بررسی می‌کنیم. این معیارها برای محاسبه تغییر اطلاعات تمیزکننده ناشی از ترکیب چندین زیرمجموعه ویژگی به کار می‌روند. مانند آنتروپی شرطی شانون، شاخص تمایز شرطی می‌تواند توانایی یک زیرمجموعه ویژگی در تمیز بین نمونه‌های با تصمیم‌های متفاوت را نشان دهد؛ هرچه شاخص تمایز شرطی کوچک‌تر باشد، توانایی تمیز آن زیرمجموعه بیشتر است. همچنین تأثیر شعاع همسایگی را بر شاخص تمایز همسایگی بررسی می‌کنیم. سپس، اهمیت ویژگی‌ها را تعریف کرده و الگوریتمی برای انتخاب ویژگی بر پایه معیارهای تمایز پیشنهادی طراحی می‌نماییم. در پایان، از مجموعه داده‌های استاندارد عمومی برای تأیید اعتبار و پایداری روش پیشنهادی و مقایسه الگوریتم جدید با روش‌های موجود استفاده می‌کنیم. نتایج آزمایش‌ها تأیید می‌کنند که معیارهای پیشنهادی برای انتخاب ویژگی، هم کارآمد و هم مؤثر هستند.

خلاصه جامع مقاله

این مقاله روشی نوین برای انتخاب ویژگی در داده‌های عددی مانند دما، درآمد یا فشارخون ارائه می‌دهد. برخلاف روش‌های پیشین که بر پایه آنتروپی شانون یا

۱. (الگوریتم اکتشافی مبتنی بر شاخص تمایز همسایگی) Heuristic Algorithm based on Neighborhood Discrimination Index

۲. (مجموعه خشن همسایگی) Neighborhood Rough Set

۳. (الگوریتم مبتنی بر آنتروپی همسایگی) Neighborhood Entropy-based algorithm

۴. (الگوریتم مبتنی بر آنتروپی اطلاعات فازی) Fuzzy Information Entropy-based algorithm

۵. Fuzzy Rough Set dependence constructed by INTersection operations of fuzzy similarity relations

(الگوریتم مبتنی بر وابستگی مجموعه خشن فازی با استفاده از عملگر اشتراک روابط شباهت فازی)

همچنین مشخص شد که پارامترهای مختلف، تأثیر قابل توجهی بر عملکرد الگوریتم انتخاب ویژگی دارند؛ بنابراین، انتخاب مقدار مناسب برای آستانه (به ویژه شعاع همسایگی) برای هر مجموعه داده، بر اساس رفتار داده‌ها ضروری است [۶۷].

منبع

[67] C. Wang, Q. Hu, X. Wang, D. Chen, Y. Qian, and Z. Dong, "Feature Selection Based on Neighborhood Discrimination Index," IEEE Transactions on Neural Networks and Learning Systems, vol. 29, no. 7, pp. 2986–2999, Jul. 2018.



برای مشاهده مقاله کامل و به زبان اصلی، می‌توانید کیو آر کد بالا را اسکن کنید،

یا بر روی **این دکمه** کلیک کنید!

تعداد کمتری ویژگی انتخاب کرد، درعین حال دقت طبقه‌بندی را حفظ کرد، و در بسیاری از موارد بهبود بخشید. همچنین، زمان اجرای آن سریع‌تر از NEIEN و FINEN بود. به طور خاص، این الگوریتم توانست با تعداد ویژگی کمتر، دقت طبقه‌بندی بالاتری نسبت به روش‌های مبتنی بر آنتروپی یگر یا مجموعه‌های خشن فازی کسب کند. نتایج نشان داد که مقدار بهینه شعاع همسایگی معمولاً در بازه ۰.۱ تا ۰.۶ قرار دارد و در این محدوده، دقت طبقه‌بندی پایدار می‌ماند.

این یافته نشان می‌دهد که روش پیشنهادی از نظر نظری جایگزینی منطقی برای آنتروپی در داده‌های عددی است، و همچنین در عمل نیز کارآمدتر، سریع‌تر و مؤثرتر عمل می‌کند. این روش می‌تواند به طور چشمگیری سرعت، دقت و قابلیت تفسیرپذیری سیستم‌های هوش مصنوعی را افزایش دهد.

نتیجه‌گیری مقاله

معیارهای سنجش توانایی یک زیرمجموعه ویژگی در تمایز بین نمونه‌ها، نقش مهمی در یادگیری طبقه‌بندی و انتخاب ویژگی دارند. با توجه به کارایی آنتروپی اطلاعات، این معیار به طور گسترده‌ای برای ارزیابی ویژگی‌ها مورد استفاده قرار گرفته است. در این مقاله، ایده‌های پایه‌ای نظریه اطلاعات شانون را در چارچوب روابط همسایگی وارد کرده و شاخص‌های تمایز را برای سنجش توانایی تمایز یک زیرمجموعه ویژگی پیشنهاد می‌کنیم. این شاخص‌ها مستقیماً بر پایه رابطه همسایگی تعریف شده و با محاسبه کاردینالیتی رابطه همسایگی، نه کلاس‌های شباهت همسایگی، به دست می‌آیند. این رویکرد، پیچیدگی محاسباتی را کاهش می‌دهد.

بر پایه این معیارهای تمایز، الگوریتم جدیدی برای انتخاب ویژگی طراحی شد. آزمایش‌ها روی سیزده مجموعه داده استاندارد تأیید کرد که روش پیشنهادی ویژگی‌های کمتری انتخاب می‌کند، و دقت طبقه‌بندی را حفظ یا بهبود می‌بخشد و همچنین زمان اجرای کمتری نسبت به بیشتر روش‌های رقیب دارد. این یافته‌ها نشان می‌دهد که شاخص تمایز همسایگی جایگزینی کارآمد و نظری برای آنتروپی در داده‌های عددی است. روش پیشنهادی به ویژه برای حوزه‌هایی مانند پزشکی، ژنتیک و بینایی ماشین که با داده‌های پیچیده و پربعدی سروکار دارند، امیدبخش است.

مانند مصرف ۶۴ لیتر آب برای هر پرسش ChatGPT مبنای واقعی ندارد. او توضیح داد مشکل مصرف آب مربوط به سامانه‌های خنک‌سازی قدیمی بوده که اکنون کنار گذاشته شده‌اند. آلتمن تأکید کرد روایت‌های منتشرشده درباره مصرف آب اغراق‌آمیز و نادرست هستند.

او در عین حال نگرانی درباره مصرف انرژی هوش مصنوعی را منصفانه دانست و گفت مسئله اصلی مصرف انرژی در مقیاس کلان است. آلتمن توضیح داد انسان نیز برای رسیدن به توانایی فکری به حدود ۲۰ سال زمان و مصرف انرژی نیاز دارد. او افزود توانایی شناختی انسان نتیجه فرایند طولانی تکامل و تجربه میلیاردها انسان در طول تاریخ است.

آلتمن گفت مقایسه منصفانه باید بین انرژی لازم برای پاسخ‌گویی ChatGPT پس از آموزش و انرژی لازم برای پاسخ‌گویی انسان انجام شود. او تأکید کرد راه‌حل اصلی، گذار سریع به انرژی‌های پاک مانند هسته‌ای، باد و خورشید است. در حال حاضر نیز الزام قانونی برای انتشار دقیق آمار مصرف آب و انرژی شرکت‌های فناوری وجود ندارد.



وعده بزرگ مدیرعامل انویدیا؛ رونمایی از تراشه‌ای در کنفرانس GTC ۲۰۲۶ که جهان را شگفت‌زده می‌کند [۷۰].

جنسن هوانگ اعلام کرده انویدیا در GTC ۲۰۲۶ از تراشه‌ای «شگفت‌انگیز» رونمایی می‌کند؛ محصولی که احتمالاً بر پایه معماری Rubin است و با ادغام حافظه‌های HBM۴ روی لایه منطقی GPU، گلوگاه‌های حافظه را حذف می‌کند. برخی گزارش‌ها احتمال بسیار کمتری هم برای نمایش اولیه معماری آینده Feynman مطرح کرده‌اند؛ معماری‌ای که با فوتونیک سیلیسیم و فرآیند ۱.۶ نانومتری می‌تواند محدودیت‌های قانون مور را جابه‌جا کند.

این وعده در شرایط رقابت شدید با AMD و تراشه‌های اختصاصی گوگل، آمازون و مایکروسافت مطرح شده و هم‌زمان نگرانی‌هایی درباره رسیدن صنعت به «دیوار مقیاس‌پذیری» وجود دارد؛ نقطه‌ای که افزایش پردازنده‌ها دیگر رشد مدل‌های هوش مصنوعی را تضمین نمی‌کند. اگر انویدیا جهش بزرگی نشان دهد، این تراشه می‌تواند مسیر نسل بعدی سخت‌افزارهای AI را تعیین کند.



سم آلتمن: جهان با «آبرهوش» تا سال ۲۰۲۸ وارد مرحله‌ای تازه می‌شود [۶۸].

سم آلتمن، مدیرعامل اوپن‌ای‌آی، امروز در اجلاس تأثیر هوش مصنوعی هند ۲۰۲۶ در دهلی‌نو درباره آینده هوش مصنوعی و مسیر توسعه آبرهوش (سوپر اینتلیجنس) سخنرانی کرد. وی در جریان این سخنرانی اعلام کرد: «با روند فعلی، ما معتقدیم ممکن است تنها چند سال تا نسخه‌های اولیه‌ای از آبرهوش واقعی فاصله داشته باشیم.»

وی افزود:

«اگر برآورد ما درست باشد، تا پایان سال ۲۰۲۸ ممکن است بخش بیشتری از ظرفیت فکری جهان درون مراکز داده قرار داشته باشد تا خارج از آن‌ها. این ادعای بسیار قابل‌توجهی است و البته ممکن است اشتباه کنیم، اما به نظر من واقعاً شایسته بررسی جدی است.»

سم آلتمن در ادامه اضافه کرد:

«یک آبرهوش، در مقطعی از مسیر توسعه خود، می‌تواند در نقش مدیرعامل یک شرکت بزرگ عملکردی بهتر از هر مدیرعامل، و قطعاً بهتر از من، داشته باشد یا پژوهشی فراتر از توان بهترین دانشمندان ما انجام دهد.»



سم آلتمن در دفاع از هوش مصنوعی: انسان هم انرژی زیادی مصرف می‌کند [۶۹].

سم آلتمن، مدیرعامل OpenAI، نگرانی‌ها درباره مصرف آب هوش مصنوعی را «کاملاً واهی» خواند و گفت ادعاهایی

Nano Banana به تصاویر تبلیغاتی حرفه‌ای تبدیل می‌کند. این ابزار پس‌زمینه مناسب پیشنهاد می‌دهد، نور و سایه را با محیط جدید هماهنگ می‌کند و جزئیات محصول را بهبود می‌دهد. Pomelli همچنین سبک بصری برند را تحلیل می‌کند تا خروجی‌ها با هویت کسب‌وکار هماهنگ باشند و امکان استفاده از تمپلت‌های آماده نیز وجود دارد.

کاربران می‌توانند با پرامپت‌های ساده پس‌زمینه را تغییر دهند یا با آپلود یک عکس مرجع، استایل آن را روی محصول کپی کنند. همچنین با وارد کردن لینک صفحه محصول، سیستم عنوان، توضیحات و تصاویر را استخراج کرده و یک محتوای تبلیغاتی کامل می‌سازد. پلتفرم Pomelli و ابزار Photoshoot فعلاً به صورت رایگان و آزمایشی در آمریکا، کانادا، استرالیا و نیوزیلند در دسترس است.



گوگل از AI Professional Certificate برای آموزش مهارت‌های هوش مصنوعی رونمایی کرد [۷۳].

گوگل از پلتفرم آموزشی Google AI Professional Certificate رونمایی کرده که هدف آن کاربردی کردن هوش مصنوعی در محیط‌های کاری است. این برنامه در پلتفرم‌هایی مانند Udemy و کورسرا ارائه می‌شود. کاربران بدون پیش‌زمینه فنی یا دانش برنامه‌نویسی نیز می‌توانند در آن شرکت کنند.

این دوره برخلاف آموزش‌های نظری، بر انجام کارهای عملی تمرکز دارد. بیش از ۲۰٪ فعالیت عملی در آن گنجانده شده که با وظایف شغلی واقعی مانند بازاریابی و تحلیل داده مرتبط هستند. هدف برنامه تبدیل AI به ابزاری روزمره و کاربردی است.

محورهای اصلی شامل مهندسی پرامپت حرفه‌ای، Vibe Coding، زنجیره‌سازی وظایف و تحلیل داده‌های ساختارنیافته است. کاربران می‌توانند بدون کدنویسی اپلیکیشن بسازند و جریان‌های کاری خودکار ایجاد کنند. این مدرک از ۷ دوره مجزا تشکیل شده که هرکدام حدود یک ساعت زمان می‌برند.



متا پس از انویدیا سراغ AMD رفت؛ خرید تراشه هوش مصنوعی با قرارداد ۱۰۰ میلیارد دلاری [۷۱].

متا قرارداد چندساله بزرگی با AMD برای خرید تراشه‌های هوش مصنوعی امضا کرده که ارزش آن حدود ۱۰۰ میلیارد دلار برآورد می‌شود. این قرارداد شامل تأمین ۶ گیگاوات ظرفیت پردازشی با استفاده از GPU و CPU برای دیتاسنترهای هوش مصنوعی متا است. AMD پردازشگرهای گرافیکی سفارشی Instinct را در قالب سرورهای Helios ارائه می‌دهد و ارسال آنها از نیمه دوم ۲۰۲۶ آغاز خواهد شد.

این قرارداد به متا اجازه می‌دهد تا سقف ۱۰ درصد از سهام AMD را خریداری کند و انتشار خبر آن باعث رشد ۱۲ درصدی سهام این شرکت شد. متا قصد دارد ۳۰ دیتاسنتر جدید بسازد تا رقابت با شرکت‌هایی مانند OpenAI و آنتروپیک را تقویت کند. این توافق یک نقطه عطف مهم برای AMD محسوب می‌شود که در تلاش است سهم بیشتری از بازار تراشه‌های هوش مصنوعی را به دست آورد.



گوگل از ابزار هوش مصنوعی Photoshoot رونمایی کرد؛ ساخت تصاویر تبلیغاتی حرفه‌ای [۷۲].

گوگل ابزار جدید Photoshoot را به پلتفرم بازاریابی هوش مصنوعی Pomelli اضافه کرده؛ یک استودیوی مجازی رایگان که عکس‌های ساده موبایلی را با کمک مدل

ثانیه‌ای بسازند یا قطعات موجود را ریمیکس کنند. این مدل در قابلیت Dream Track یوتوب نیز برای ساخت موسیقی پس‌زمینه Shorts استفاده می‌شود و امکان کنترل جزئیاتی مثل تمپو و سبک درامزنی را فراهم می‌کند. جمینای حتی می‌تواند براساس عکس یا ویدیو آهنگ تولید کند و مدل تصویری Nano Banana نیز کاور هنری می‌سازد.

گوگل می‌گوید ۳ Lyria نسبت به مدل‌های قبلی، موسیقی «واقع‌گرایانه‌تر و پیچیده‌تر» تولید می‌کند و توانایی ساخت شعر را هم دارد. خروجی‌ها فعلاً به کلیپ‌های ۳۰ ثانیه‌ای محدود هستند و همه آهنگ‌ها با واترمارک SynthID منتشر می‌شوند. این قابلیت اکنون فعال است و کاربران بالای ۱۸ سال می‌توانند به زبان‌هایی مانند انگلیسی، اسپانیایی، آلمانی، فرانسوی، هندی، ژاپنی، کره‌ای و پرتغالی از آن استفاده کنند.

Nano Banana 2 is here.

Our latest state of the art image model. Now you can get the advanced world knowledge, quality and reasoning you love, at the fast speed you need to bring your wildest ideas to life.

Try Nano Banana 2

مدل Nano Banana ۲ معرفی شد؛ قوی‌ترین هوش مصنوعی تصویرساز گوگل [۷۶].

گوگل از مدل جدید تولید تصویر خود با نام Nano Banana ۲ رونمایی کرد؛ مدلی که دقت نسخه Pro را با سرعت پردازش Gemini Flash ترکیب کرده و نسل تازه‌ای از خلق تصویر مبتنی بر هوش مصنوعی را رقم می‌زند. این نسخه توانایی تولید اینفوگرافیک‌های دقیق، رندر واقع‌گرایانه سوژه‌ها، درج و ترجمه صحیح متن در تصویر و اجرای ویرایش‌های سریع و مرحله‌ای را با کیفیت بالاتر در نور، جزئیات و انسجام بصری فراهم می‌کند.

مدل Nano Banana ۲ با ارتقای «پایداری سوژه» (حفظ کاراکترها و اشیای متعدد در یک جریان کاری)، تبعیت دقیق‌تر از دستورات و پشتیبانی از خروجی تا وضوح ۴K، تعادل کم‌سابقه‌ای میان سرعت و دقت ایجاد کرده است. این مدل همچنین با بهره‌گیری از فناوری‌های نشانه‌گذاری محتوای تولیدشده با هوش مصنوعی، بر شفافیت و اعتمادپذیری خروجی‌ها تأکید دارد.

نانو بنانا ۲ از امروز از طریق اپ جمینای، گوگل AI استودیو و همچنین ابزار آنتی‌گرویتی گوگل در دسترس است.



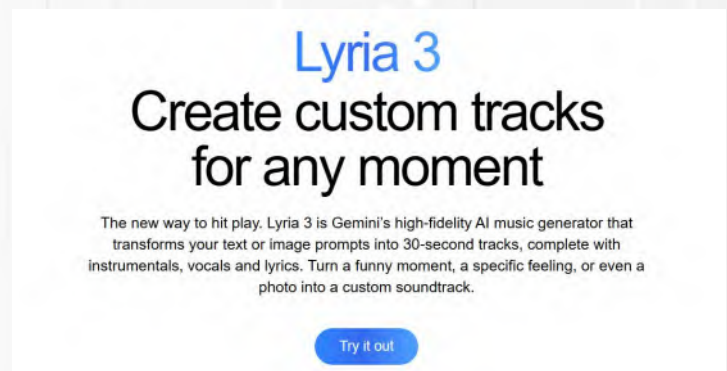
گوگل از جمینای ۳.۱ پرو رونمایی کرد؛ از بهبود حل مسائل پیچیده تا ارتقای توانمندی‌های گرافیکی [۷۴].

گوگل نسخه جدید مدل هوش مصنوعی خود با نام «جمینای ۳.۱ پرو» را معرفی کرد؛ مدلی که به گفته این شرکت با هدف ارتقای توانایی استدلال، حل مسائل پیچیده و تولید خروجی‌های دقیق‌تر توسعه یافته است.

در معرفی این مدل، گوگل به بهبود عملکرد در برخی بنچمارک‌های تخصصی و افزایش توانایی پاسخ‌گویی به پرسش‌های چندلایه و انتزاعی اشاره کرده است.

همچنین تمرکز ویژه‌ای بر قابلیت‌های گرافیکی و تولید شبیه‌سازی‌ها در این نسخه، دیده می‌شود؛ جایی که نمونه‌های ارائه‌شده نشان می‌دهد خروجی‌های بصری از نظر طراحی و ساختار منسجم‌تر شده‌اند.

به گفته گوگل، توسعه‌دهندگانی که از این مدل برای ایجاد گردش‌کارهای عامل‌محور استفاده می‌کنند نیز احتمالاً شاهد بهبود عملکرد خواهند بود. جمینای ۳.۱ پرو در قالب نسخه پیش‌نمایش برای توسعه‌دهندگان، کاربران سازمانی و همچنین کاربران عادی در برخی سرویس‌ها عرضه شده است.



جمینای وارد دنیای موسیقی شد؛ تولید آهنگ‌های ۳۰ ثانیه‌ای با مدل جدید ۳ Lyria [۷۵].

گوگل مدل صوتی ۳ Lyria را به جمینای اضافه کرده تا کاربران بتوانند تنها با یک دستور متنی، آهنگ‌های ۳۰

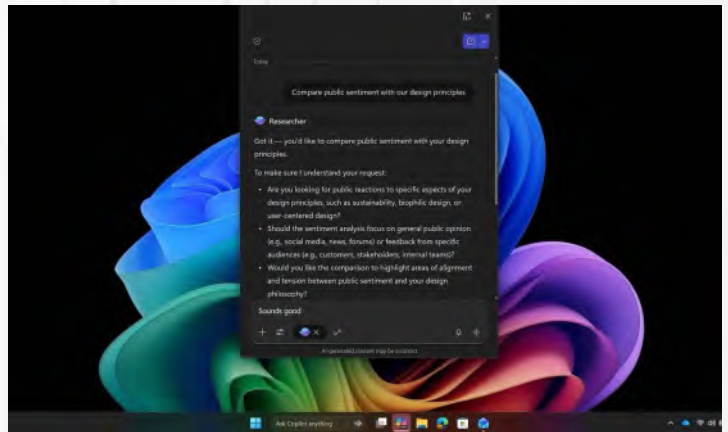
ماشین‌های مجازی ایزوله، امکان اجرای نرم‌افزار، تست، دیباگ و حتی تعامل با وبسایت‌ها را فراهم می‌سازد. این ایجنت‌ها می‌توانند ویدیو و اسکرین‌شات تهیه کنند، تداخل‌های Merge را حل کنند و یک Pull Request نهایی ارائه دهند؛ به طوری که بیش از ۳۰ درصد پول‌ریکوئست‌های داخلی شرکت در ماه گذشته توسط همین ایجنت‌ها مدیریت شده است. در دموهای اخیر، این ایجنت‌ها آسیب‌پذیری‌ها را بازسازی کرده، سرورهای تست را بالا آورده و تست‌های رابط کاربری را به صورت کامل انجام داده‌اند. تیم Cursor می‌گوید این قابلیت‌ها آغاز مسیر «مخازن کد خودران» است؛ جایی که توسعه‌دهنده نقش مدیر استراتژیک را دارد و ایجنت‌ها تمام مراحل از توسعه تا مانیتورینگ نسخه نهایی را انجام می‌دهند.



هشدار محققان MIT: اکثر ایجنت‌های هوش مصنوعی امن نیستند [۷۹].

گزارش جدید محققان MIT نشان می‌دهد بسیاری از ایجنت‌های هوش مصنوعی از نظر شفافیت و کنترل امنیتی در وضعیت خطرناک قرار دارند. از میان ۳۰ سیستم بررسی‌شده، تعدادی هیچ نظارتی بر استفاده کاربران ندارند، بسیاری ماهیت ربانی خود را فاش نمی‌کنند و حتی دکمه توقف اضطراری ندارند. محققان هشدار می‌دهند ایجنت‌هایی که به ایمیل‌ها و دیتابیس‌ها متصل‌اند، در صورت رفتار اشتباه می‌توانند بدون امکان توقف، آسیب جدی ایجاد کنند.


در ارزیابی نمونه‌ها، تنها ChatGPT Agent رفتار خود را با امضای رمزنگاری‌شده ثبت می‌کرد. ابزارهایی مثل Comet فاقد تست ایمنی و محیط ایزوله‌اند و حتی به دلیل جعل هویت انسانی مورد شکایت قرار گرفته‌اند. برخی ابزارهای سازمانی نیز نتایج واقعی تست‌های امنیتی را پنهان می‌کنند. محققان تأکید می‌کنند اگر این خلأهای امنیتی برطرف نشود، توسعه‌دهندگان به زودی با رگولاتوری سخت‌گیرانه روبه‌رو خواهند شد.



هوش مصنوعی کوپایلت به تسک‌بار و فایل اکسپلورر ویندوز ۱۱ می‌آید [۷۷].

مایکروسافت کوپایلت را مستقیماً وارد تسک‌بار و فایل اکسپلورر ویندوز ۱۱ کرده تا جستجوی ساده قدیمی را به یک ابزار هوشمند تبدیل کند. کاربران می‌توانند سؤال‌هایی مثل «ارزیابی عملکردم چه زمانی است» بپرسند و سیستم پاسخ را از ایمیل‌ها، تقویم و فایل‌های محلی استخراج می‌کند. با تایپ کاراکتر @ نیز فهرست «عوامل هوش مصنوعی» نمایش داده می‌شود و وضعیت کارهایشان روی تسک‌بار قابل مشاهده است.

در فایل اکسپلورر هم Copilot Control اضافه شده تا بدون باز کردن اسناد بتوان درباره محتوای آن‌ها سؤال پرسید و فایل‌های OneDrive و SharePoint در کنار فایل‌های محلی نمایش داده شوند. این قابلیت‌ها بسته به سخت‌افزار فعال می‌شوند؛ نسخه معمولی ویندوز ابزارهای ابری را دریافت می‌کند و دستگاه‌های Copilot+ به دلیل داشتن NPU از قابلیت‌های آفلاین بیشتری بهره‌مند می‌شوند. هم‌زمان، گوگل نیز قابلیت تحلیل محلی PDF را با جمعینای به اپلیکیشن Files اندروید آورده است.



انقلاب در برنامه‌نویسی؛ ایجنت‌های هوشمند Cursor حالا کامپیوتر را کنترل می‌کنند [۷۸].

کمپانی Cursor قابلیت Cloud Agents را معرفی کرده که فراتر از تولید کد عمل می‌کند و با اتصال کاربر به

هوشمند با نمایشگر شفاف ساخته شده است. در این عینک‌ها رابط کاربری روی لنز نیست و در عمق حدود یکمتری دیده می‌شود، جایی که کاربر باید آگاهانه فوکوسش را از دنیای واقعی به صفحه مجازی منتقل کند. گوگل برای جلوگیری از حواس‌پرتی، انیمیشن‌های آرام‌تری مثل انتقال دوثانیه‌ای برای نوتیفیکیشن‌ها طراحی کرده و برای خوانایی بهتر از فونت Google Sans Flex و اندازه‌گذاری مبتنی بر «زاویه دید» استفاده می‌کند.

به دلیل ماهیت افزایشی نمایشگرها، این عینک‌ها نمی‌توانند رنگ سیاه تولید کنند و همین موضوع باعث شد اصول متریال دیزاین در این محیط ناکارآمد باشد. Glimmer با پس‌زمینه‌های تیره، سایه‌های عمیق و رنگ‌های خنثی مشکل هاله نور را کاهش می‌دهد و خوانایی را بالا می‌برد.



وضعیت قرمز در بازار امنیت سایبری؛ Claude Code Security لریزه بر اندام شرکت‌ها انداخت [۸۲].

آنتروپیک قابلیت Claude Code Security را معرفی کرده که می‌تواند کدهای نرم‌افزاری را بررسی و آسیب‌پذیری‌ها را شناسایی کند. این ابزار برای هر مشکل، وصله پیشنهادی ارائه می‌دهد تا اصلاح سریع‌تر انجام شود. هدف آن کمک به رفع کمبود نیروی متخصص امنیت نرم‌افزار است، نه جایگزینی کامل انسان.


پس از معرفی این ابزار، سهام شرکت‌های امنیت سایبری مانند CrowdStrike، Cloudflare، SailPoint و Okta حدود ۸ تا ۹ درصد سقوط کرد. سرمایه‌گذاران نگران شده‌اند که این فناوری برخی خدمات امنیتی موجود را کم‌اهمیت کند. درعین‌حال، این ابزار می‌تواند بهره‌وری تیم‌های امنیتی را افزایش دهد.



تبعیض پنهان چت‌بات‌ها: هوش مصنوعی به کاربران ایرانی پاسخ‌های ضعیف‌تری می‌دهد [۸۰].


پژوهش دانشگاه MIT نشان می‌دهد مدل‌های زبانی بزرگ مانند Claude ۳ Opus، GPT-۴، و Llama ۳ گاهی به کاربران با تسلط کمتر به انگلیسی، تحصیلات پایین‌تر یا خارج از آمریکا پاسخ‌های ضعیف‌تر و غیرواقعی‌تر می‌دهند. این موضوع می‌تواند هدف کاهش نابرابری اطلاعاتی را تحت تأثیر قرار دهد.

در آزمایش‌ها، دقت پاسخ‌ها برای کاربران غیرانگلیسی‌زبان و کم‌تحصیل به‌طور قابل‌توجهی کاهش یافت. عملکرد Claude ۳ Opus برای کاربران اهل ایران در هر دو مجموعه داده به شکل معناداری ضعیف‌تر بود. این مدل همچنین بیشتر از پاسخ دادن به سؤالات این کاربران خودداری کرد. مدل Claude در برخی موارد لحنی تحقیرآمیز داشت یا انگلیسی شکسته را تقلید کرد. همچنین از ارائه اطلاعات درباره موضوعاتی مانند انرژی هسته‌ای و تاریخ برای کاربران ایرانی یا روسی با تحصیلات پایین خودداری کرد. پژوهشگران هشدار دادند قابلیت‌های شخصی‌سازی می‌تواند خطر رفتار تبعیض‌آمیز را افزایش دهد.



انقلاب بصری گوگل در دنیای واقعیت افزوده؛ با سیستم طراحی Glimmer آشنا شوید [۸۱].

گوگل جزئیات سیستم طراحی Glimmer را برای اندروید XR منتشر کرده؛ چارچوبی که مخصوص عینک‌های



ارتباط ماهواره‌ای آیفون جان ۶ اسکی‌باز را در آمریکا نجات داد [۸۵].

در پی سقوط یک بهمن در نزدیکی دریاچه تاهو، شش اسکی‌باز با استفاده از قابلیت ارتباط اضطراری ماهواره‌ای آیفون توانستند با نیروهای امدادی تماس بگیرند و جان سالم به در ببرند. این گروه طی چهار ساعت ارتباط پایدار با دفتر کلانتر برقرار کرد و همین موضوع به تیم‌های نجات کمک کرد تا موقعیت دقیق حادثه را سریع‌تر پیدا کنند. قابلیت پیام اضطراری ماهواره‌ای اپل تاکنون جان افراد زیادی را در حوادث خارج از پوشش شبکه نجات داده و در کشورهای مختلف فعال است. آیفون‌های سری ۱۴ تا ۱۷ و اپل واچ اولترا ۳ از این ویژگی پشتیبانی می‌کنند و گوشی پس از اتصال به ماهواره، اطلاعات حیاتی مانند موقعیت دقیق و وضعیت باتری را برای نیروهای امدادی ارسال می‌کند. اپل این سرویس را دو سال اول به صورت رایگان ارائه می‌دهد.



مدیرعامل Real Vision: با هوش مصنوعی دانش بی‌ارزش می‌شود [۸۳].

رائول پال، مدیرعامل Real Vision، هوش مصنوعی را بزرگ‌ترین اختراع بشر دانست و گفت این فناوری دانش را بی‌ارزش می‌کند. او معتقد است ارزش بالای برخی مشاغل به دلیل کمیاب بودن دانش بوده است. هوش مصنوعی با دسترسی سریع به اطلاعات این مزیت را از بین می‌برد.

پال می‌گوید حوزه‌هایی مانند حقوق، پزشکی و امور مالی در حال تبدیل شدن به کالا هستند. ابزارهایی مانند ChatGPT، جمینای و Claude می‌توانند اطلاعات تخصصی را در چند ثانیه ارائه دهند. این موضوع می‌تواند مدل‌های اقتصادی مبتنی بر فروش دانش را تغییر دهد.



کارآفرین آمریکایی: اگر توسعه‌دهنده هستید، به هیچ وجه از ابزارهای OpenAI استفاده نکنید [۸۴]!

جیسون کالاکانیس، سرمایه‌گذار سابق سیلیکون ولی، با اشاره به استراتژی‌های انحصارطلبانه غول‌هایی مثل مایکروسافت و فیس‌بوک، هشدار داده که OpenAI در حال تکرار همان الگوست. او معتقد است سم آلتمن از توسعه‌دهندگان به عنوان آزمایشگاهی برای شناسایی ایده‌های سودآور استفاده می‌کند تا در نهایت با عرضه محصولات مشابه، آن‌ها را از بازار حذف کند.

- [1] howsam Team, "یادگیری نورون مصنوعی", * howsam*, May. 28, 2020. [Online]. Available: <https://howsam.org/artificial-neuron/>
-
- [2] Z. Xu, S. Jain, and M. Kankanhalli, "Hallucination is inevitable: An innate limitation of large language models," arXiv, Jan. 2024.
- [3] S. Liu et al., "Towards long context hallucination detection," arXiv, Apr. 2025.
- [4] Nature, "Detecting hallucinations in large language models using semantic uncertainty estimators," Nature, 2024.
- [5] Peter Hess, "How memory augmentation can improve large language models," IBM Research Blog. [Online]. Available: <https://research.ibm.com/blog/memory-augmented-LLMs>.
- [6] A. Kostikova et al., "LLMs: A data-driven survey of evolving research on limitations of large language models," arXiv, May 2025.
- [7] Wikipedia, "Knowledge cutoff," Wikipedia. [Online]. Available: https://en.wikipedia.org/wiki/Knowledge_cutoff.
- [8] Stanford HAI, "Hallucinating law: Legal mistakes in large language models are pervasive," Stanford HAI. [Online]. Available: <https://hai.stanford.edu>.
- [9] Nexla, "LLM hallucination — Types, causes, and solutions," Nexla. [Online]. Available: <https://nexla.com/ai-infrastructure/llm-hallucination/>.
-
- [10] E. Strubell, P. Ganesh, and A. McCallum, "Energy and Policy Considerations for Deep Learning in NLP," in Proc. 57th Annual Meeting of the Association for Computational Linguistics (ACL), Florence, Italy, Jul. 2019, pp. 3645–3650.
- [12] L. Bouza Heguerte, A. Bugeau, and L. Lannelongue, "How to Estimate Carbon Footprint When Training Deep Learning Models? A Guide and Review," Energy for AI, vol. 1, no. 1, pp. 1–12, Mar. 2021.
- [13] International Energy Agency (IEA), CO₂ Emissions from Fuel Combustion: Highlights. Paris, France: IEA Publications, 2019.
- [14] L. F. W. Anthony, B. Kanding, and R. Selvan, "CarbonTracker: Tracking and Predicting the Carbon Footprint of Training Deep Learning Models," in Proc. ACM Conf. on Fairness, Accountability, and Transparency (FAccT), Barcelona, Spain, Jan. 2020, pp. 355–363.
- [15] L. Lannelongue, J. Grealey, and M. Inouye, "Green Algorithms: Quantifying the Carbon Footprint of Computation," Advanced Science, vol. 8, no. 12, pp. 1–8, Jun. 2021.
- [16] H. Patel, R. Gupta, S. Kumar, and A. Singh, "Energy-Efficient Strategies for Deep Learning Models," IEEE Transactions on Sustainable Computing, vol. 6, no. 4, pp. 1123–1135, Oct.–Dec. 2020.
- [17] M. Zhang, H. Zhang, and Z. Li, "Tracking Carbon Footprint in AI Models: A Detailed Approach," Computer Science Review, vol. 44, pp. 37–45, Nov. 2020.
- [18] E. Barbierato and A. Gatti, "Toward Green AI: A Methodological Survey of the Scientific Literature," Neurocomputing, vol. 599, pp. 128096, Sep. 2024.
-
- [19] I. Goodfellow et al., "Generative adversarial nets," in Proc. Advances in Neural Information Processing Systems, vol. 27, pp. 2672–2680, 2014.
- [20] V. C. Pezoulas et al., "Synthetic data generation methods in healthcare: A review on open-source tools and methods," Computational and Structural Biotechnology Journal, vol. 22, pp. 3910–3925, 2024.
- [21] C. Yan, "Generating synthetic electronic health record data using GANs," JMIR AI, vol. 3, Art. no. e52615, 2024.
- [22] M. Loni, Y. Xiang, and J. Zhang, "A review on generative AI models for synthetic medical text, time-series, and longitudinal data," NPJ Digital Medicine, vol. 7, Art. no. 77, 2024.
- [23] M. Frid-Adar et al., "Synthetic data augmentation using GAN for improved liver lesion classification," arXiv, 2018.

- [24] M. Miletic and J. Zhang, "Utility-based analysis of statistical approaches and deep learning for synthetic data generation in healthcare," *JMIR AI*, vol. 3, Art. no. e65729, 2025.
- [25] B. Kaabachi and F. Poursalim, "A scoping review of privacy and utility metrics in medical synthetic data evaluation," *NPJ Digital Medicine*, vol. 7, Art. no. 59, 2025.
- [26] A. Shmatko and Y. Ye, "Learning the natural history of human disease with synthetic data: A comprehensive review," *Nature*, vol. 618, pp. 95–129, 2025.
-
- [27] N. Bostrom, *Superintelligence: Paths, Dangers, Strategies*. Oxford, U.K.: Oxford Univ. Press, 2014.
- [28] C. Bishop, "Artificial intelligence in video game development," *IEEE Transactions on Games*, vol. 12, no. 3, pp. 205–217, 2020.
- [29] M. Yannakakis and J. Togelius, *Artificial Intelligence and Games*. Cham, Switzerland: Springer, 2018.
- [30] A. Douglas, "Noughts and Crosses Machine," in *Proc. Univ. of Cambridge Colloquium on Computing Machinery*, Cambridge, U.K., 1952.
- [31] D. Kushner, "The legacy of Dune II: The RTS revolution," *IEEE Spectrum*, 2019.
- [32] W. Wright, "Simulating life: The Sims AI system," in *Proc. Game Developers Conference (GDC)*, San Jose, CA, USA, 2001.
- [33] Monolith Productions, "Nemesis System in Shadow of War," *Shadow of War*. [Online]. Available: <https://www.shadowofwar.com/about/>.
- [34] Chris Esaki, "Forza Motorsport: Drivatar system overview," *Forza Motorsport*. [Online]. Available: <https://forza.net/news/forza-motorsport-drivatars-tire-physics>.
- [35] Bungie Studios, "Behavior trees in Halo AI," in *Proc. Game Developers Conference (GDC)*, San Francisco, CA, USA, 2005.
- [36] DeepMind, "AlphaStar: Mastering StarCraft II with Deep Reinforcement Learning," *Nature*, vol. 575, pp. 350–354, 2019.
- [37] Runway ML, "Introducing Game Worlds," *Runway ML*. [Online]. Available: <https://runwayml.com/research/runway-game-worlds>.
- [38] The AlphaStar team, "AlphaStar: Mastering StarCraft II with Deep Reinforcement Learning," *DeepMind Blog*. [Online]. Available: <https://deepmind.google/blog/alphastar-mastering-the-real-time-strategy-game-starcraft-ii/>.
- [39] Monolith Productions, "F.E.A.R AI system overview," in *Proc. Game Developers Conference (GDC)*, San Francisco, CA, USA, 2005.
- [40] J. Togelius, "Procedural content generation in games," *ACM Computing Surveys*, vol. 45, no. 3, pp. 1–38, 2016.
- [41] S. K. Panchal, R. Verma, and L. Gupta, "Algorithmic procedural generation in No Man's Sky," *International Journal of Game Design Studies*, vol. 5, no. 2, pp. 112–126, 2020.
- [42] A. Liapis, J. Togelius, and G. N. Yannakakis, "Generative design in Minecraft (GDMC): An AI competition," in *Proc. IEEE Conf. on Games (CoG)*, 2018.
- [43] R. Hendriks, S. Meijer, J. Van Der Velden, and A. Iosup, "Procedural content generation for roguelike games," *Entertainment Computing*, vol. 4, no. 1, pp. 1–13, 2013.
- [44] Valve, "Left 4 Dead: The AI Director," in *Proc. Game Developers Conference (GDC)*, San Francisco, CA, USA, 2009.
- [45] OREATE AI, "Exploring Riot Vanguard: The Anti-Cheat System Behind Your Favorite Games," *Oreate AI Blog*. [Online]. Available: <https://www.oreateai.com/blog/exploring-riot-vanguard-the-anticheat-system-behind-your-favorite-games/8c7519d24bcb95241de194eae8925dee#:~:text=Vanguard%20operates%20continuously%20in%20the,anything%20see%20amiss%20during%20gameplay/>.

- [46] Mathieu Nayrolles, Abdelwahab Hamou-Lhadj, "Commit Assistant: AI bug prediction," Montreal Ubisoft Blog. [Online]. Available: <https://montreal.ubisoft.com/en/ubisoft-la-forge-presents-the-commit-assistant/>.
- [47] NVIDIA, "DLSS 3.5 technical whitepaper," NVIDIA Developer Portal. [Online]. Available: <https://developer.nvidia.com/rtx/dlss>.
- [48] Inworld AI, "Intelligent NPCs platform," Inworld Official Site. [Online]. Available: <https://inworld.ai/gaming-and-media>.
- [49] Blizzard Entertainment, "Overwatch balance analytics," Blizzard Developer Blog. [Online]. Available: <https://news.blizzard.com/en-gb/article/23896785/overwatch-2-developer-blog-matchmaker-and-competitive-deep-dive-part-1>.
- [50] J. McKernan, "AI and creative labor in game design," Game Studies Journal, vol. 22, no. 4, 2022.
- [51] H. Becker, "Emotion recognition for interactive NPCs," in Proc. IEEE Conf. on Games (CoG), Aug. 2023, pp. 1-8.
- [52] Runway ML, "Prompt-to-game generation," Runway ML Blog. [Online]. Available: <https://runwayml.com/ai-for-gaming>.
- [53] M. Rowe, "Generative storytelling in interactive media," Entertainment Computing, vol. 50, pp. 100573, 2024.
-
- [54] A. K. Cline, Introductory Cardinality Theory. Lecture Notes / Monograph.
- [55] S. Demiralp, "New insights into rough set theory: Transitive neighborhoods and approximations," Symmetry, vol. 16, no. 9, Art. no. 1237, 2024.
- [56] Z. Pawlak, "Rough sets," International Journal of Computer & Information Sciences, vol. 11, no. 5, pp. 341-356, 1982.
- [57] P. Zhang et al., "Fuzzy rough set models based on fuzzy similarity relation and information granularity in multi-source mixed information systems," Mathematics, vol. 12, no. 24, Art. no. 4039, 2024.
- [58] D. Ellerman, "Introduction to logical entropy and its relationship to Shannon entropy," Entropy, vol. 20, no. 9, Art. no. 679, 2018.
- [59] C. E. Shannon, "A mathematical theory of communication," The Bell System Technical Journal, vol. 27, pp. 379-423 and 623-656, 1948.
- [60] R. R. Yager, "On the measure of fuzziness and negation. Part I: Membership in the unit interval," International Journal of General Systems, vol. 5, no. 4, pp. 221-229, 1979.
- [61] M.-S. Yang and Z. Hussain, "Fuzzy entropy for Pythagorean fuzzy sets with application to multicriterion decision making," Complexity, Art. no. 2830957, 2018.
- [62] F. Deroncourt, Introduction to Fuzzy Logic. Lecture Notes, MIT.
- [63] L. A. Zadeh, "Fuzzy sets," Information and Control, vol. 8, no. 3, pp. 338-353, 1965.
- [64] A. K. Tiwari et al., "Hybrid similarity relation-based mutual information for feature selection in intuitionistic fuzzy rough framework and its applications," Scientific Reports, vol. 12, Art. no. 11249, 2022.
- [65] A. García, "Greedy algorithms: A review and open problems," Journal of Inequalities and Applications, vol. 2025, no. 1, Art. no. 36, 2025.
- [66] N. Kokash, An Introduction to Heuristic Algorithms. Technical Report / Tutorial.
-
- [67] C. Wang, Q. Hu, X. Wang, D. Chen, Y. Qian, and Z. Dong, "Feature Selection Based on Neighborhood Discrimination Index," IEEE Transactions on Neural Networks and Learning Systems, vol. 29, no. 7, pp. 2986-2999, Jul. 2018.
-
- [68] digiato team, "اسم آتمن: جهان با «آبرهوش» تا سال ۲۰۲۸ وارد مرحله‌ای تازه می‌شود," *digiato*, Feb 19, 2026. [Online]. Available: <https://digiato.com/>

- [69] digiatio team, "سم آلتمن در دفاع از هوش مصنوعی: انسان هم انرژی زیادی مصرف می‌کند", *digiatio*, Feb 22, 2026. [Online]. Available: <https://digiatio.com/>
- [70] digiatio team, "GTC 2026 وعده بزرگ مدیرعامل انویدیا؛ رونمایی از تراشه‌ای که جهان را شگفت‌زده می‌کند در کنفرانس", *digiatio*, Feb 19, 2026. [Online]. Available: <https://digiatio.com/>
- [71] digiatio team, "رفت؛ خرید تراشه هوش مصنوعی با قرارداد ۱۰۰ میلیارد دلاری AMD متا پس از انویدیا سراغ", *digiatio*, Feb 24, 2026. [Online]. Available: <https://digiatio.com/>
- [72] digiatio team, "رونمایی کرد؛ ساخت تصاویر تبلیغاتی حرفه‌ای Photoshoot گوگل از ابزار هوش مصنوعی", *digiatio*, Feb 20, 2026. [Online]. Available: <https://digiatio.com/>
- [73] digiatio team, "برای آموزش مهارت‌های هوش مصنوعی رونمایی کرد AI Professional Certificate گوگل از", *digiatio*, Feb 22, 2026. [Online]. Available: <https://digiatio.com/>
- [74] digiatio team, "گوگل از جمینای ۳.۱ پرو رونمایی کرد؛ از بهبود حل مسائل پیچیده تا ارتقای توانمندی‌های گرافیکی", *digiatio*, Feb 19, 2026. [Online]. Available: <https://digiatio.com/>
- [75] digiatio team, "Lyria 3 جمینای وارد دنیای موسیقی شد؛ تولید آهنگ‌های ۳۰ ثانیه‌ای با مدل جدید", *digiatio*, Feb 19, 2026. [Online]. Available: <https://digiatio.com/>
- [76] digiatio team, "معرفی شد؛ قوی‌ترین هوش مصنوعی تصویرساز گوگل Nano Banana 2 مدل", *digiatio*, Feb 26, 2026. [Online]. Available: <https://digiatio.com/>
- [77] digiatio team, "هوش مصنوعی کوپایلت به تسک‌بار و فایل اکسپلورر ویندوز ۱۱ می‌آید", *digiatio*, Feb 25, 2026. [Online]. Available: <https://digiatio.com/>
- [78] digiatio team, "حالا کامپیوتر را کنترل می‌کنند Cursor انقلاب در برنامه‌نویسی؛ ایجت‌های هوشمند", *digiatio*, Feb 25, 2026. [Online]. Available: <https://digiatio.com/>
- [79] digiatio team, "اکثر ایجت‌های هوش مصنوعی امن نیستند: MIT هشدار محققان", *digiatio*, Feb 20, 2026. [Online]. Available: <https://digiatio.com/>
- [80] digiatio team, "تبعیض پنهان چت‌بات‌ها: هوش مصنوعی به کاربران ایرانی پاسخ‌های ضعیف‌تری می‌دهد", *digiatio*, Feb 21, 2026. [Online]. Available: <https://digiatio.com/>
- [81] digiatio team, "آشنا شوید Glimmer انقلاب بصری گوگل در دنیای واقعیت افزوده؛ با سیستم طراحی", *digiatio*, Feb 19, 2026. [Online]. Available: <https://digiatio.com/>
- [82] digiatio team, "لرزه بر اندام شرکت‌ها انداخت Claude Code Security وضعیت قرمز در بازار امنیت سایبری؛", *digiatio*, Feb 22, 2026. [Online]. Available: <https://digiatio.com/>
- [83] digiatio team, "با هوش مصنوعی دانش بی‌ارزش می‌شود: Real Vision مدیرعامل", *digiatio*, Feb 21, 2026. [Online]. Available: <https://digiatio.com/>
- [84] digiatio team, "استفاده نکنید OpenAI کارآفرین آمریکایی: اگر توسعه‌دهنده هستید، به هیچ‌وجه از ابزارهای", *digiatio*, Feb 23, 2026. [Online]. Available: <https://digiatio.com/>
- [85] digiatio team, "ارتباط ماهواره‌ای آیفون جان ۶ اسکی‌باز را در آمریکا نجات داد", *digiatio*, Feb 20, 2026. [Online]. Available: <https://digiatio.com/>



هوشی نو

مجله گاه نامه انجمن هوش مصنوعی دانشگاه اراک

کلیه حقوق پخش و انتشار این نشریه متعلق به
انجمن علمی هوش مصنوعی دانشگاه اراک می باشد.