

تبغیض شیء ها و رسم مرزهای تصمیم گیری می پردازند. دسته دیگر که Generative ها هستند، وظیفه شان این است که یک داده ای را تولید کنند. برای اینکه این داده جدید تولید شود باید مدل هوش مصنوعی توانایی یادگیری یک توزیع احتمال یا توزیع یادگیری را یاد بگیرد. برای مثال انسان یک مدل Generative است، اگر از او خواسته شود تا نقاشی یک خانه را بکشد بدون آنکه خانه ای را ببیند می تواند آن را رسم کند لذا نقاش یک دانشی از شکل و شما می یک خانه دارد. پس هدف این مدل ها یادگیری توزیع داده است. یک مثال دیگر برای مدل های Generative، مدل های GAN هستند که به طور غیرمستقیم در حال یادگیری توزیع احتمال اند اما در واقع قصد نمونه برداری یا Sampling از آن توزیع احتمال را دارند. حال سوالی مطرح میشود که چطور امکان دارد مدل یک توزیع را یاد بگیرد؟

ابتدا باید بررسی کنیم مفهوم توزیع چیست؟ دیدگاه آماری اشاره می کند که اگر بخواهیم توزیع احتمالاتی یک واقعه را به دست بباوریم به این واقعه یک عدد نسبت می دهد که اگر n بار آزمایش این واقعه تکرار شود نسبت تعداد بار به وقوع پیوستن این واقعه به n احتمال آن است. حال اگر این فرایند برای هر واقعه انجام شود توزیع احتمال داده به دست می آید. مدل های هوش مصنوعی در بخش طبقه بنده تاکنون قادر به تخمین مقدار این احتمال بوده اند اما آیا امکانش هست که تابع توزیع احتمال را برای هر مقدار ورودی تخمین زد؟

تابع انرژی مفهومی است که در علوم مختلف مانند فیزیک، شیمی، و بیولوژی به کار می رود. این تابع به ما می گوید که یک سیستم یا شیء، چقدر انرژی دارد. در واقع، می توانیم آن را به عنوان "مقداری" که به اندازه گیری انرژی یک موجود یا سیستم کمک می کند، تصور کنیم. وقتی یک سیستم تغییر می کند، تابع انرژی می تواند به ما نشان دهد که چگونه انرژی درون آن تغییر می کند. تابع انرژی در شبکه های عصبی معمولاً به عنوان یک معیار برای اندازه گیری عملکرد شبکه استفاده می شود. این تابع به ما می گوید که شبکه چقدر در پیش بینی نتایج، درست عمل می کند. وقتی شبکه عصبی با داده های ورودی کار می کند، تابع انرژی مقداری مشخص را اختصاص می دهد که نشان می دهد چقدر پیش بینی های شبکه از واقعیت می تواند اختلاف داشته باشد. هدف ما در آموزش شبکه عصبی این است که تابع انرژی را به حداقل برسانیم، به این معنا که پیش بینی های شبکه به نتایج واقعی نزدیک تر شوند. برای راحتی کار در پیاده سازی، تابع توزیع را به صورت یک تابع نرمال انرژی تبدیل می کنیم. نکته قابل توجه می تواند این باشد که به جای تابع توزیع در فرمول، میتوانیم یک شبکه عصبی را بگذاریم.

این فرمول مشهور که از توزیع احتمال به نام "تابع توزیع احتمال گشتی" (Gibbs distribution) مشتق شده است، به مانشان می دهد که انرژی یک شبکه عصبی به عنوان توانایی

Score Matching

در هوش مصنوعی

تکنیک Score Matching یک ابزار قدرتمند در آمار و احتمالات است که به ما کمک می کند تا داده ها را بهتر در کرده و مدل های احتمالاتی را بهینه تر سازیم. این تکنیک به ما این امکان را می دهد که با تطبیق توزیع های احتمالاتی مدل های مختلف به داده های مشاهده شده، مدل مناسبی را ایجاد کنیم. اهمیت Score Matching در این است که به




پویا اردکانی
دانشجو و مهندس کامپیوتر
دانشکده فنی دانشگاه تهران
pouya.ardehkhani@ut.ac.ir

ما این قدرت را می دهد تا به طور دقیق تر و بهبود یافته تری توزیع های احتمالاتی را برای داده ها مدل کنیم، که این موضوع در مسائلی مانند یادگیری ماشین، تحلیل داده ها، و پیش بینی احتمالی پدیده ها بسیار مهم است. به طور ساده، Matching به ما امکان می دهد داده های پیچیده را بهتر درک کنیم و مدل هایمان را بهبود ببخشیم، که این امر به تحقیقات بیشتر و بهترین استفاده از داده های ما منجر می شود.

برای فهم بهتر این تکنیک، ابتدا مدل های هوش مصنوعی را باید به دو گروه تقسیم کنیم. گروه اول Discriminative ها و گروه دوم Generative ها هستند.

Models: Discriminative vs. Generative




Discriminative Models
Discriminate between objects

Generative Models
Learning distribution

شكل-۱

Discriminative به معنای جدا کردن دو یا چند چیز از هم دیگر است، به عبارتی دیگر، انگار بین شیء های یک مرز مشخصی را تعیین میکنند. در اصل این مدل ها تنها به



شکل-۲ نمونه استفاده از تکنیک Score Matching

در این تکنیک شما تلاش می‌کنید تا تغییرات در نحوه عملکرد تابع توزیع را در کناید. امتیازها (Scores) معیاری هستند که به شما کمک می‌کنند این تغییرات را بسنجید. شما مقدار امتیازها را بین داده‌های واقعی و داده‌های تخمینی مدل مقایسه می‌کنید. اگر امتیازها مشابه باشند، تخمین مدل هوش مصنوعی خوب است. مدل نیز یاد می‌گیرد که چگونه توزیع داده‌ها را بهتر تخمین بزند. این تخمین باعث می‌شود که یک تخمین از تابع توزیع از داده‌ها به وجود آید همانند آنچه در شکل ۲ می‌بینید. این تکنیک به مدل‌های هوش مصنوعی کمک می‌کند تا بدون نیاز به محاسبات پیچیده، توزیع متغیرهای تصادفی را بهتر بفهمد و در مسائل مختلفی استفاده و نمونه سازی کند.


استفاده از تکنیک Score Matching در شبکه‌های عصبی بسیار اهمیت دارد. یکی از اصولی‌ترین مسائل در آموزش شبکه‌های عصبی، تنظیم پارامترها به منظور بهبود کارایی مدل است. این تکنیک به ما امکان می‌دهد توزیع ویژگی‌ها در داده‌ها را به دقت تخمین بزنیم، بدون نیاز به محاسبه مستقیم توزیع. با داشتن این اطلاعات، می‌توانیم در فرآیند آموزش شبکه‌ها، از روش‌های بهبود کارایی مانند روش‌های بهینه‌سازی تطبیقی بهره وری کنیم تا شبکه بهبودیافتهد را ایجاد کنیم. این می‌تواند منجر به آموزش سریع‌تر و دقیق‌تری در شبکه‌های عصبی شود.

علاوه بر این، Score Matching به ما کمک می‌کند توزیع‌های احتمالی پشت مشتقات ویژگی‌ها را تخمین بزنیم. این اطلاعات می‌توانند در فرآیند انتخاب ساختار مدل و مدیریت مشکلات آموزشی مانند مشکل کاهش گرادیان‌ها (vanishing/exploding gradient) کمک کنند. در نتیجه، استفاده از تکنیک Score Matching به افزایش عملکرد و پایداری شبکه‌های عصبی کمک می‌کند و می‌تواند در تعمیق درک ما از رفتار شبکه‌ها و بهبود توانایی آن‌ها در مسائل مختلف مفید باشد.

شبکه در توجه به داده‌ها و نمونه‌های ورودی را اندازه‌گیری می‌کند. در واقع، این فرمول نسبت توزیع احتمالی به انرژی را نشان می‌دهد و با تعیین مقادیر مناسب برای ثابت عدد، مانند توانیم توزیع احتمالی را به انرژی متناظر با آن مرتبط کنیم. این تبدیل از توزیع به انرژی به ما کمک می‌کند تا برای مسائل مختلفی مانند یادگیری ماشینی و پردازش سیگنال، مدل‌های بهتری ایجاد کنیم و داده‌های ورودی را بهبود بخشیم.

همچنین این فرمول ارتباطی را نمایان می‌کند که در شبکه‌های عصبی برای محاسبه انرژی یک وضعیت خاص استفاده می‌شود. در اینجا، "انرژی تابع" نشان‌دهنده مقدار انرژی مرتبط با وضعیت خاصی در شبکه عصبی است. این مقدار بر اساس خروجی شبکه برای آن وضعیت و تقسیم بر یک ثابت عدد محاسبه می‌شود. از تابع انرژی برای ارزیابی کیفیت پیش‌بینی‌های شبکه عصبی استفاده می‌شود، به طوری که مقدار کمتر انرژی به نتایج دقیق‌تر نزدیک‌تر است. این فرمول به ما کمک می‌کند تا عملکرد شبکه را ارزیابی کنیم و در صورت لزوم، شبکه را بهبود دهیم.

حال یک سوال دیگر مطرح می‌شود که آیا این عدد ثابت به راحتی قابل به دست آوردن است؟ خیر، محاسبات این عدد به قدری زیاد است که به نظر مشکل می‌آید. پس باید به تخمین زدن این عدد بپردازیم. اینجا تکنیک Score Matching مطرح می‌شود.



ایده اصلی پشت تکنیک Score Matching این است که می‌خواهد توزیع یک متغیر تصادفی را بدون نیاز به محاسبه مستقیم توزیع آن تخمین بزند. به جای محاسبه توزیع، این تکنیک از امتیازها (Scores) استفاده می‌کند که نشان‌دهنده تغییرات تابع توزیع مورد نظر در مورد پارامترهای آن است. با مقایسه امتیازها بین داده‌های مشاهده شده و داده‌های تولید شده از مدل تخمینی، می‌توان توزیع مورد نظر را تخمین زد. در متغیر تصادفی و احتمالات، امتیاز (Score) به تغییرات لگاریتم توزیع احتمالی متغیر تصادفی نسبت به پارامترهای آن توزیع اشاره دارد. به عبارت دیگر، امتیاز نشان‌دهنده تاثیر تغییرات در پارامترهای توزیع بر توزیع احتمالی متغیر تصادفی است.