


هوش محاسباتی

Computational Intelligence

میلاذ سلطانی






فهرست مطالب فصل دوم

- شبکه عصبی به زبان ساده
- تاریخچه و کاربردهای شبکه عصبی
- تفاوت شبکه عصبی و سایر الگوریتم های یادگیری ماشین
- ساختار و نحوه عملکرد سلول عصبی
- مدل سازی و نحوه عملکرد نورون پایه
- انواع توابع فعال سازی
- شبکه عصبی تک لایه و چند لایه
- پیش خور (Feedforward)
- الگوریتم پس انتشار (Backpropagation)
- الگوریتم گرادیان نزولی (Gradient Descent)

شبکه های عصبی مصنوعی Artificial Neural Networks

(قسمت اول)




مقدمه‌ای بر شبکه‌های عصبی

■ شبکه‌های عصبی مصنوعی (Artificial Neural Networks) از ساختار و عملکرد مغز انسان الهام گرفته و شامل مجموعه‌ای از واحدهای محاسباتی به نام نورون متصل به هم بوده و به صورت لایه‌ای سازماندهی می‌شوند.

* در شبکه‌های مصنوعی تلاش بر این است که با استفاده از عناصر عملکردی سیستم عصبی و مغز، از بخش خاصی از قدرت شناختی انسان (به ویژه قدرت یادگیری) تقلید شود.

■ ایده اصلی

- * شبیه‌سازی نحوه‌ی یادگیری و پردازش اطلاعات در مغز انسان
- * مغز از میلیاردها سلول عصبی (نورون) تشکیل شده که از طریق سیناپس به یکدیگر متصل هستند.
- * هر نورون با دریافت ورودی، آن را پردازش کرده و خروجی تولید شده را به نورون‌های دیگر منتقل می‌کند.





مفهوم شبکه عصبی به زبان ساده

■ مفهوم شبکه عصبی مثل این است که بخواهیم به یک کودک یاد بدهیم که چگونه از بین اشکال مختلف، شکل دایره را تشخیص دهد.


* به او چندین عکس از دایره‌ها در ابعاد و رنگ‌های مختلف نشان می‌دهیم. پس از مدتی یاد می‌گیرد که دایره چیست و می‌تواند از میان همه تصاویری که به او نشان داده می‌شود، دایره‌ها را تشخیص دهد.

* این عملکرد دقیقاً همان کاری‌ست که به کمک شبکه‌های عصبی برای آموزش به یک ماشین انجام می‌دهیم؛ آموزش دادن به ماشین نهایتاً باعث ایجاد هوش مصنوعی در آن می‌شود.





شبکه عصبی و هوش مصنوعی



کاربردهای شبکه عصبی

■ داده کاوی و تحلیل داده

- * تشخیص الگوها در داده‌های بزرگ
- * تحلیل بازار و پیش‌بینی قیمت سهام
- * شناسایی تقلب در تراکنش‌های بانکی

■ سیستم‌های توصیه‌گر

- * پیشنهاد فیلم، موسیقی یا کتاب
- * پیشنهاد کالا در فروشگاه‌های آنلاین

■ مدل‌سازی و شبیه‌سازی

- * مدل‌سازی پدیده‌های پیچیده فیزیکی، شیمیایی یا زیستی
- * شبیه‌سازی فرآیندهای صنعتی و علمی

■ پردازش تصویر و بینایی کامپیوتر


- * تشخیص اشیاء، چهره‌ها و الگوها
- * پردازش و تحلیل تصاویر پزشکی

■ پردازش زبان طبیعی (NLP)

- * ترجمه ماشینی و تشخیص گفتار
- * تولید متون و پاسخ‌دهی خودکار
- * تحلیل احساسات

■ علوم پزشکی

- * پیش‌بینی بیماری‌ها
- * طراحی داروها
- * تحلیل داده‌های ژنتیکی



کاربردهای شبکه عصبی

■ رباتیک

- * کنترل حرکتی ربات‌ها
- * درک و پاسخ به محیط
- * یادگیری وظایف جدید توسط ربات‌ها

■ خودروهای خودران


- * مسیریابی و ناوبری
- * تشخیص موانع و علائم ترافیکی
- * تحلیل داده‌های سنسورها

■ کنترل و بهینه‌سازی

- * کنترل فرآیندهای صنعتی
- * بهینه‌سازی مصرف انرژی
- * طراحی خودکار سیستم‌های مهندسی

■ بازی‌ها و سرگرمی

- * طراحی هوش مصنوعی بازی‌ها
- * تولید محتوای گرافیکی و صوتی
- * شبیه‌سازی شخصیت‌ها



تاریخچه شبکه‌های عصبی مصنوعی

■ آغاز ایده (دهه ۱۹۴۰)


* اولین مدل شبکه‌های عصبی مصنوعی در سال ۱۹۴۳ با تشریح اولین مدل رسمی یک نورون محاسباتی ابتدایی توسط وارن مک کالک (Warren McCulloch) فیزیولوژیست عصبی و والتر پیتز (Walter Pitts) ریاضیدان ارائه شد.

■ ظهور پرسپترون (دهه ۱۹۵۰ و ۱۹۶۰)

* فرانک روزنبلات در سال ۱۹۵۸، اولین مدل شبکه عصبی قابل یادگیری به نام "پرسپترون" را توسعه داد.

* پرسپترون قادر به یادگیری از داده‌ها بود، اما محدودیت‌هایی داشت، از جمله عدم توانایی در حل مسائل غیرخطی.







تاریخچه شبکه‌های عصبی مصنوعی

■ در سال ۱۹۵۹، برنارد ویدرو (Bernard Widrow) و مارسیان هاف (Marcian Hoff) از دانشگاه استنفورد مدل‌هایی را توسعه دادند که اولین شبکه‌های عصبی به کار گرفته شده در مسائل واقعی بودند.

* ADALINE (Adaptive Linear Elements)


* MADALINE (Multiple ADALINE)

■ این مدل‌ها، قانون یادگیری ویدرو-هاف و اولین شبکه عصبی را تشکیل دادند که برای یک مسأله دنیای واقعی اعمال شد.



$$O = \begin{cases} 1 & \text{if } \sum_{i=1}^n w_i x_i - b \geq T \\ 0 & \text{if } \sum_{i=1}^n w_i x_i - b < T \end{cases}$$

where $i = 1, 2, \dots, n$ and b is called bias.




تاریخچه شبکه‌های عصبی مصنوعی

■ دوران رکود (دهه ۱۹۷۰)

- * انتقاد ماروین مینسکی و سیمور پاپرت: در کتابی به نام Perceptrons، محدودیت‌های پرسپترون تک لایه‌ای را برجسته کردند. این انتقادات باعث کاهش علاقه به شبکه‌های عصبی شد.
- * عدم وجود سخت‌افزار و الگوریتم‌های مناسب نیز یکی از دلایل رکود بود.

■ احیا و توسعه (دهه ۱۹۸۰)


- * ابداع الگوریتم پس‌انتشار خطا (Backpropagation): در دهه ۱۹۸۰، روش پس‌انتشار خطا برای آموزش شبکه‌های عصبی چندلایه ارائه شد. این الگوریتم توانست مسائل غیرخطی را حل کند و باعث احیای شبکه‌های عصبی شد.
- * پژوهشگران مانند دیوید رومل‌هارت و جفری هینتون نقش کلیدی در توسعه این روش داشتند.



تاریخچه شبکه‌های عصبی مصنوعی

■ احیا و توسعه (دهه ۱۹۸۰)

Hopfield Network (HN)



* شبکه‌های خود سازمان‌ده (Self-Organizing Maps - SOM)


- ◀ توسط تئوو کوهونن (Teuvo Kohonen) در دهه ۱۹۸۰ توسعه یافت.
- ◀ این شبکه‌ها برای کاهش ابعاد داده و خوشه‌بندی (Clustering) استفاده می‌شوند.

* شبکه‌های بولتزمن (Boltzmann Machines)

- ◀ توسط جفری هینتون معرفی شدند.
- ◀ این مدل‌ها برای یادگیری احتمالاتی و مسائل بهینه‌سازی استفاده می‌شوند.

* شبکه‌های بازگشتی (Recurrent Neural Networks - RNN)

- ◀ جان هاپفیلد (John Hopfield) مدل‌های بازگشتی را توسعه داد که امکان مدل‌سازی سری‌های زمانی و حافظه کوتاه‌مدت را فراهم کردند.



تاریخچه شبکه‌های عصبی مصنوعی

■ توسعه الگوریتم‌ها و مدل‌های پیشرفته (دهه ۱۹۹۰)

* شبکه‌های عصبی پیچشی (Convolutional Neural Networks - CNNs)


◀ شبکه‌های عصبی پیچشی که در دهه ۱۹۸۰ معرفی شدند، در این دهه توسط یان لیکان (Yann LeCun) و تیم او توسعه یافتند.

◀ CNNها به دلیل توانایی بالا در پردازش تصویر، به یکی از پُر کاربردترین مدل‌های شبکه‌های عصبی تبدیل شدند.

* شبکه‌های بازگشتی (Recurrent Neural Networks - RNNs)

◀ RNNها در دهه ۱۹۹۰ برای پردازش داده‌های سری زمانی و زبان‌های طبیعی پیشرفت‌های چشمگیری داشتند.

◀ الگوریتم‌های پیشرفته مثل Long Short-Term Memory (LSTM) توسط سِپ هوچریتِر (Sepp Hochreiter) و یورگن اشمید هوبر (Jürgen Schmidhuber) در سال ۱۹۹۷ معرفی شدند.



تاریخچه شبکه‌های عصبی مصنوعی


■ رشد چشمگیر (دهه ۲۰۰۰)

* ظهور یادگیری عمیق (Deep Learning)

- ◀ با پیشرفت سخت‌افزار (بویژه پردازنده‌های گرافیکی) و دسترسی به داده‌های بزرگ، شبکه‌های عصبی عمیق با لایه‌های متعدد مورد استفاده قرار گرفتند.
- ◀ معماری‌هایی مانند شبکه‌های پیچشی (CNN) برای پردازش تصویر و شبکه‌های بازگشتی (RNN) برای پردازش سری‌های زمانی و زبان توسعه یافتند.

* پیشرفت سخت‌افزاری

- ◀ استفاده از پردازنده‌های گرافیکی (GPUs) به دلیل توانایی پردازش موازی بالا، سرعت آموزش شبکه‌های عصبی را به طرز چشمگیری افزایش دادند.



تاریخچه شبکه‌های عصبی مصنوعی

■ کاربردهای مدرن (دهه ۲۰۱۰)

* گسترش یادگیری عمیق (Deep Learning)


- ◀ ImageNet در سال ۲۰۱۲ با استفاده از CNN ها، دقت تشخیص تصویر را به طور قابل توجهی افزایش داد.
- ◀ AlphaGo محصول شرکت (DeepMind) با شکست لی سدول، قهرمان جهانی بازی Go، قدرت یادگیری عمیق و یادگیری تقویتی (Reinforcement Learning) را نشان داد.

* پیشرفت در مدل‌های شبکه‌های عصبی

- ◀ استفاده از Transformer ها و مدل‌هایی مانند GPT و BERT برای پردازش زبان طبیعی و کاربردهای پیشرفته‌تر

* توسعه ابزارهای متن باز و چارچوب‌ها

- ◀ TensorFlow (2015)
- ◀ PyTorch (2016)
- ◀ Keras



تاریخچه شبکه‌های عصبی مصنوعی

■ دهه فعلی کاربردهای فوق چشمگیر (از دهه ۲۰۲۰ به بعد)

* ظهور مدل‌های بزرگ زبان (Large Language Models - LLMs)

◀ معماری‌هایی مانند Transformer و مدل‌هایی مانند GPT و BERT برای پردازش زبان طبیعی و کاربردهای پیشرفته‌تری به کار گرفته شدند.

* ترکیب شبکه‌های عصبی با روش‌های جدید


◀ معماری‌های چند وجهی (Multimodal Models) مانند CLIP (OpenAI) - DALL-E (OpenAI) - Stable Diffusion - MidJourney

* پیشرفت در توان محاسباتی

◀ تراشه‌های تخصصی

◀ رشد محاسبات ابری: دسترسی به منابع محاسباتی عظیم توسط AWS، Google Cloud و Microsoft Azure

* یادگیری انتقالی (Transfer Learning)



تفاوت شبکه‌های عصبی با سایر روش‌های یادگیری ماشین

■ ساختار و الهام‌گیری زیستی

* شبکه‌های عصبی مصنوعی

◀ ساختار شبکه‌های عصبی از مغز انسان الهام گرفته شده است.

* سایر روش‌های یادگیری ماشین:

◀ بیشتر آن‌ها بر اساس مفاهیم آماری یا الگوریتم‌های خاص طراحی شده و معمولاً ساختاری ساده‌تر دارند.


■ قابلیت یادگیری ویژگی‌ها

* شبکه‌های عصبی:

◀ شبکه‌های عصبی توانایی یادگیری خودکار ویژگی‌ها (Feature Learning) از داده‌های خام را دارند.

* سایر روش‌ها:

◀ معمولاً نیاز به پیش‌پردازش و استخراج ویژگی‌های دستی دارند.



تفاوت شبکه‌های عصبی با سایر روش‌های یادگیری ماشین

■ عملکرد در مسائل پیچیده و داده‌های بزرگ

* شبکه‌های عصبی:

◀ در حل مسائل پیچیده با داده‌های بزرگ و چندبُعدی (مانند تصاویر، ویدئوها، و متن) بسیار قدرتمند هستند.

* سایر روش‌ها:

◀ در مسائل ساده یا داده‌های کم، اغلب کارایی بهتری دارند و سریع‌تر آموزش می‌بینند.


■ انعطاف‌پذیری

* شبکه‌های عصبی:

◀ قابل استفاده در دامنه‌های مختلف از تشخیص تصویر و صدا گرفته تا پردازش زبان طبیعی و بازی‌ها.

* سایر روش‌ها:

◀ انعطاف‌پذیری کمتری دارند و معمولاً برای مسائل خاص بهینه‌سازی می‌شوند.



تفاوت شبکه‌های عصبی با سایر روش‌های یادگیری ماشین

■ تفسیرپذیری

* شبکه‌های عصبی:

◀ تفسیر فرایند یادگیری آن‌ها دشوار است، چرا که شامل هزاران یا میلیون‌ها پارامتر می‌شوند.

* سایر روش‌ها:

◀ روش‌هایی مانند درخت تصمیم یا رگرسیون خطی تفسیرپذیرتر بوده و فهم نتایج و روابط میان ویژگی‌ها در آن‌ها ساده‌تر است.


■ کاربردها

* شبکه‌های عصبی:

◀ مناسب برای مسائل پیچیده که نیاز به درک عمیق از داده‌ها دارند، مانند ترجمه ماشینی


* سایر روش‌ها:

◀ بیشتر در مسائل ساده‌تر یا جایی که داده‌ها محدود هستند، استفاده می‌شوند، مانند خوشه‌بندی اولیه



ساختار و ویژگی های سلول عصبی

■ سیستم عصبی انسان از سلول هایی به نام نورون (Neuron) ساخته شده و اجزای آن:



* سوما (Cell body)(Soma)

* دندريت (Cell input)(Dendrite)

* آکسون (Cell output)(Axon)

* سیناپس (Neuron contact (Synapses)

■ مغز انسان بصورت موازی پردازش می کند.


* تعداد 10^{11} نورون در مغز وجود دارد


* هر نورون به 10^4 نورون دیگر متصل است

■ سرعت پاسخ نورون ها از مدارهای الکتریکی کندتر است.

* نورون در 10^{-3} ثانیه و مدار الکتریکی در 10^{-9} ثانیه پاسخ می دهد

NEURON





عملکرد سلول عصبی

■ آکسون از یک نورون به دندریت های نورون های دیگر در نقطه سیناپس منتهی می شود.


■ انتقال دهنده عصبی نوروترنسمیتر (Neurotransmitter) از آکسون آزاد و روی غشای دندریت دریافت کننده سبب تغییر پتانسیل الکتریکی می شود.


* سیناپس کاهنده اختلاف پتانسیل، تحریک کننده (Excitatory) است.

* سیناپس افزایشنده اختلاف پتانسیل، بازدارنده (Inhibitory) است.

■ اگر یک نورون به اندازه کافی ورودی محرک دریافت کند و مقدار ورودی به یک آستانه مشخص برسد، نورون فعال شده و به نورون های دیگر سیگنال (تکانه عصبی) ارسال می کند.

* تعداد تکانه های عصبی ارسالی یک نورون در هر ثانیه **نرخ شلیک (Firing Rate)** نامیده می شود.






مدل نورون پایه

■ در نورون بیولوژیکی اگر مجموع ورودی ها نسبت به آستانه (Threshold):

* بیشتر باشد، نورون فعال است (یک)

* کمتر باشد، نورون غیرفعال است (صفر)




■ مقادیر x_i ورودی ها

■ مقادیر w_i وزن ها

■ مقدار y خروجی

■ مقدار θ آستانه


$$y = \begin{cases} 1 & \text{if } \sum_{i=1}^n w_i x_i \geq \theta, \\ 0 & \text{otherwise.} \end{cases}$$




مثال نورون پایه برای ترکیب عطفی

■ برای پیاده سازی ترکیب عطفی (AND) یک نورون پایه با دو ورودی x_1 و x_2 با وزن های $w_1=3$ و $w_2=2$ و آستانه $\theta=4$ در نظر می گیریم.


$$x_1 \wedge x_2 \Rightarrow \sum_{i=1}^2 w_i x_i \Rightarrow 3x_1 + 2x_2 \Rightarrow y = \begin{cases} 1, & 3x_1 + 2x_2 \geq 4 \\ 0, & \text{otherwise} \end{cases}$$



x_1	x_2	$3x_1 + 2x_2$	y
0	0	0	0
1	0	3	0
0	1	2	0
1	1	5	1




شکل هندسی پیاده سازی ترکیب عطفی (AND) برای $x_1 \wedge x_2$ که خط درون شکل دارای معادله $3x_1 + 2x_2 = 4$ است و برای بخش خاکستری، معادله برابر است با $3x_1 + 2x_2 \geq 4$





مثال نورون پایه برای ترکیب شرطی

■ برای پیاده سازی ترکیب شرطی ($\rightarrow$) یک نورون پایه با دو ورودی x_1 و x_2 دارای وزن های $w_1=2$ و $w_2=-2$ و آستانه $\theta=-1$ در نظر می گیریم.


$$x_1 \rightarrow x_2 \Rightarrow \sum_{i=1}^2 w_i x_i \Rightarrow 2x_1 - 2x_2 \Rightarrow y = \begin{cases} 1, & 2x_1 - 2x_2 \geq -1 \\ 0, & \text{otherwise} \end{cases}$$



x_1	x_2	$2x_1 - 2x_2$	y
0	0	0	1
1	0	2	1
0	1	-2	0
1	1	0	1



شکل هندسی پیاده سازی ترکیب شرطی ($\rightarrow$) برای $x_2 \rightarrow x_1$ که خط درون شکل دارای معادله $2x_1 - 2x_2 = -1$ است و برای بخش خاکستری، معادله برابر است با $2x_1 - 2x_2 \geq -1$




مثال نورون پایه برای یک عبارت پیچیده

■ برای پیاده سازی یک عبارت پیچیده، یک نورون پایه با سه ورودی x_1 و x_2 و x_3 با وزن های $w_1=2$ و $w_2=-2$ و $w_3=2$ آستانه $\theta=1$ در نظر می گیریم.


$$(x_1 \wedge \overline{x_2}) \vee (x_1 \wedge x_3) \vee (\overline{x_2} \wedge x_3) \Rightarrow$$

$$\sum_{i=1}^3 w_i x_i \Rightarrow 2x_1 - 2x_2 + 2x_3 \Rightarrow$$


$$y = \begin{cases} 1, & 2x_1 - 2x_2 + 2x_3 \geq 1 \\ 0, & \text{otherwise} \end{cases}$$



x_1	x_2	x_3	$\sum_i w_i x_i$	y
0	0	0	0	0
1	0	0	2	1
0	1	0	-2	0
1	1	0	0	0
0	0	1	2	1
1	0	1	4	1
0	1	1	0	0
1	1	1	2	1




شکل هندسی پیاده سازی برای $(x_1 \wedge \overline{x_2}) \vee (x_1 \wedge x_3) \vee (\overline{x_2} \wedge x_3)$ که صفحه درون شکل دارای معادله $2x_1 - 2x_2 + 2x_3 = -1$ است.




محدودیت قدرت بیان و محاسبات نورون پایه

- نورون پایه تنها می تواند توابعی را نمایش دهد که تفکیک پذیر خطی هستند.
- ترکیب دو شرطی ($\leftrightarrow$) برای یک نورون پایه با دو ورودی x_1 و x_2 را در نظر می گیریم.

x_1	x_2	y
0	0	1
1	0	0
0	1	0
1	1	1




تفکیک پذیر
نیست




شبکه نورون های پایه


- تمام توابع بولی با هر تعداد ورودی دلخواه را می توان با شبکه نورون های پایه محاسبه کرد.
- شبکه دو لایه می تواند توابع بولی را پیاده سازی کند.
- برای پیاده سازی ترکیب دو شرطی ($\leftrightarrow$) شبکه نورون پایه با دو ورودی x_1 و x_2 دارای آستانه و وزن های زیر در نظر می گیریم.



$$x_1 \leftrightarrow x_2 \implies (x_1 \rightarrow x_2) \wedge (x_2 \rightarrow x_1)$$



شکل هندسی پیاده سازی برای ترکیب دو شرطی بصورت یک شبکه از نورون های پایه




مفهوم وزن (Weights)

■ وزن‌ها پارامترهایی هستند که قدرت و تأثیر هر اتصال بین نورون‌ها را تعیین می‌کنند.
■ نقش وزن‌ها در شبکه:


* وزن‌ها نشان‌دهنده اهمیت هر ورودی خاص برای محاسبات نورون هستند.

* وزن بالاتر یعنی ورودی تأثیر بیشتری و وزن پایین‌تر یعنی ورودی تأثیر کمتر بر خروجی نورون دارد.

* در طول فرآیند آموزش، وزن‌ها به‌گونه‌ای به‌روزرسانی می‌شوند که خطای پیش‌بینی کاهش یابد.



$$y = \begin{cases} 1 & \text{if } \sum_{i=1}^n w_i x_i \geq \theta, \\ 0 & \text{otherwise.} \end{cases}$$




بایاس (Bias)

- بایاس یک مقدار ثابت است که به مقدار محاسبه شده توسط نورون اضافه می شود.
- نقش بایاس در شبکه:

* بایاس به نورون اجازه می دهد خروجی را حتی زمانی که همه ورودی ها صفر هستند، تنظیم کند.

* این مقدار کمک می کند تا شبکه بتواند به صورت انعطاف پذیرتر مرز تصمیم گیری خود را تغییر دهد.




برای مثال، بدون بایاس، مرز تصمیم همیشه از مبدا (صفر) عبور می کند، اما با وجود بایاس می تواند از هر نقطه ای در فضای ویژگی ها عبور کند.




$$y = \left[\sum_{i=0}^n w_i(t) x_i(t) \pm b \right]$$

انواع توابع فعال سازی

Activation Function





تابع فعال سازی پله دودویی


■ تابع پله دودویی (Binary Step Function)

* ورودی تابع پله دودویی با مقدار حد آستانه مقایسه می‌شود. اگر مقدار ورودی از مقدار حد آستانه بیشتر باشد، گره فعال خواهد شد در غیر این صورت غیرفعال باقی می‌ماند.


* محدودیت‌ها:

◀ تابع پله دودویی نمی‌تواند خروجی‌هایی با مقادیر چندگانه تولید کند.

◀ مشتق تابع پله دودویی برابر با صفر است که این ویژگی، مانعی برای روند انتشار رو به عقب محسوب می‌شود.




$$f(x): \begin{cases} 0 & \text{for } x < 0 \\ 1 & \text{for } x \geq 0 \end{cases}$$



تابع فعال سازی خطی


■ تابع فعال سازی خطی (Linear Activation Function)



$$f(x) = x$$

- * تابع همانی (Identify Function) مجموع وزنی ورودی را بدون هیچ تغییری به خروجی منتقل می کند.
- * استفاده فقط در مدل های رگرسیون خطی
- * محدودیت ها:

- ◀ عدم استفاده در مرحله انتشار به عقب، زیرا مشتق آن یک عدد ثابت است و هیچ رابطه ای با ورودی x ندارد.
- ◀ خروجی این تابع فعال سازی در لایه آخر شبکه با خروجی تابع فعال سازی در لایه اول برابر است.
- ◀ وقتی شبکه دارای پارامترهای زیاد و پیچیده باشد، این نوع تابع فعال سازی عملکرد خوبی ندارد.



توابع فعال سازی غیر خطی


■ تابع فعالسازی غیر خطی (Non-linear Activation Function)

* این نوع توابع بیشترین استفاده را در شبکه های عصبی دارند. تعمیم پذیری و تطبیق پذیری مدل با انواع مختلف داده با استفاده از توابع فعالسازی غیر خطی آسان می شود.

* ویژگی های اصلی این توابع فعالسازی عبارتند از:


◀ این توابع مشکل مربوط به مرحله انتشار به عقب را حل کردند. به عبارتی، توابع غیر خطی در مرحله انتشار رو به عقب می توانند مشخص کنند کدام وزن گره ورودی به تشخیص نهایی مدل می تواند کمک بهتری کند.

◀ با استفاده از این توابع می توان مسائل مربوط به خروجی های چندگانه را حل کرد. به عبارتی، خروجی توابع غیر خطی، ترکیب غیر خطی از ورودی ها است که از لایه های متعدد عبور کرده است.




انواع تابع فعال ساز غیر خطی

- تابع فعال سازی سیگموئید (Sigmoid | Logistic)
- تابع فعال سازی تابع تانژانت هذلولوی (Tanh | Hyperbolic Tangent)
- تابع فعال سازی یکسوساز (ReLU)
- تابع فعال سازی یکسوساز پارامتریک (Parametric ReLU)
- تابع فعال سازی واحدهای خطی نمایی (Exponential Linear Units | ELU)
- تابع فعال سازی (Softmax)
- تابع فعال سازی (Swish)




تابع فعالسازی غیر خطی سیگموئید




$$f(x) = \frac{1}{1 + e^{-x}}$$

■ این تابع ورودی خود را به مقداری در بازه 0 تا +1 تبدیل می‌کند. هرچه مقدار ورودی بزرگ‌تر باشد، مقدار خروجی این تابع به +1 نزدیک‌تر شده و اگر مقدار ورودی کوچک باشد (عدد منفی)، مقدار خروجی این تابع به عدد 0 نزدیک‌تر می‌شود.

■ تابع سیگموئید، تابعی یکنوا (Monotonic) محسوب می‌شود اما مشتق این تابع، تابع یکنوا نیست.



تابع فعالسازی غیر خطی تانژانت هذلولوی




$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

■ تابع تانژانت هذلولوی (Hyperbolic Tangent) یا Tanh شبیه تابع سیگموئید است.

■ تابع یکنواخت است اما مشتق آن یکنواخت نیست.

■ تنها تفاوت این تابع با تابع سیگموئید، بازه خروجی این تابع است که به محدوده بین -1 تا +1 نگاشت می‌کند.




تابع فعالسازی غیر خطی یکسوساز

■ تابع واحد خطی اصلاح شده (Rectified Linear Unit) یا ReLU یکی از رایج‌ترین توابع فعالسازی در:

* شبکه‌های عصبی کانولوشنی (Convolutional Neural Networks)


* یادگیری عمیق



$$f(x) = \max(0, x)$$


■ تابع مشتق‌پذیر است و می‌توان آنرا در مرحله انتشار رو به عقب استفاده کرد.

■ این تابع تمامی گره‌ها را همزمان فعال نمی‌کند. گره‌ها زمانی غیرفعال هستند که مقدار ورودی این تابع کمتر از صفر باشد.




تابع فعالسازی غیر خطی یکسوساز پارامتریک

Leaky ReLU activation function




این تابع فعالسازی، نسخه بهبودیافته از تابع فعالسازی یکسوساز ReLU است که مشکل زوال در تابع ReLU را حل می‌کند. در این تابع برای ناحیه منفی، شیب ملایم مثبتی به اندازه a در نظر گرفته می‌شود.

$$f(x) = \max(ax, x)$$




تابع فعالسازی غیر خطی ELU

$$ELU(\alpha, x) = \begin{cases} x, & \text{if } x \geq 0 \\ \alpha(e^x - 1), & \text{otherwise} \end{cases}$$



■ تابع فعالسازی ELU یا تابع فعالسازی واحدهای خطی نمایی یکی از انواع تابع فعالسازی ReLU به حساب می‌آید.


■ در تابع فعالسازی Parametric ReLU نمودار توابع در ناحیه منفی، به صورت خط مستقیم است. تابع فعالسازی ELU برای این ناحیه، منحنی لگاریتمی تعریف می‌کند.




تابع فعالسازی غیر خطی Softmax

■ تابع فعالسازی Softmax نوعی از تابع سیگموئید به حساب می‌آید. این تابع ترکیبی از چندین تابع سیگموئید است که احتمالات نسبی را محاسبه می‌کند. به عبارتی، تابع Softmax احتمالات چندین کلاس را مشخص می‌کند.

Softmax Activation Function




$$\text{Softmax}(z_i) = \frac{\exp(z_i)}{\sum_j \exp(z_j)}$$




تابع فعالسازی غیر خطی Swish

این تابع را محققان گوگل ارائه کرده‌اند و به لحاظ کارایی، عملکرد بهتری نسبت به تابع فعالسازی ReLU در شبکه‌های عمیق دارد. از تابع فعالسازی Swish در مسائلی نظیر دسته‌بندی تصاویر و ترجمه ماشین استفاده می‌شود.

$$\sigma(x) = \frac{x}{1+e^{-x}}$$



$$f(x) = x * \text{sigmoid}(x) = x * \frac{1}{1 + e^{-x}}$$



شبکه عصبی تک لایه (Single Layer Neural Network)

■ یک شبکه عصبی تک لایه شامل:

* یک لایه ورودی برای دریافت داده‌ها.

* یک لایه خروجی برای تولید خروجی‌ها. این شبکه‌ها هیچ لایه پنهانی (Hidden Layer) ندارند.

■ ویژگی‌ها:

* ساده‌ترین نوع شبکه‌های عصبی است.


* فقط قادر به حل مسائل خطی جداناپذیر است.

* معمولاً از یک یا چندین نورون (Perceptron) موازی در لایه خروجی تشکیل شده است.

■ معایب:

* توانایی مدل‌سازی مسائل غیرخطی مانند XOR را ندارد.

* به دلیل محدودیت‌های ساختاری، برای داده‌های پیچیده مناسب نیست.



شبکه عصبی چندلایه (Multi-Layer Neural Network)

■ یک شبکه عصبی چندلایه شامل:

* یک لایه ورودی برای دریافت داده‌ها.

* یک یا چند لایه پنهان (Hidden Layer) برای پردازش و استخراج ویژگی‌های پیچیده.

* یک لایه خروجی: برای تولید نتایج نهایی.

■ ویژگی‌ها:

* مسائل خطی و غیرخطی مثل تشخیص تصاویر، پیش‌بینی سری زمانی و مسائل طبقه‌بندی را مدل‌سازی می‌کند.

* با لایه‌های پنهان شبکه می‌تواند روابط پیچیده بین ورودی‌ها و خروجی‌ها را یاد بگیرد.

* معمولاً از توابع فعال‌سازی غیرخطی استفاده می‌کند.


■ معایب:

* پیچیدگی محاسباتی بیشتر.

* نیازمند داده‌های بیشتر و زمان آموزش طولانی‌تر.

مقایسه بین شبکه عصبی تک‌لایه و چندلایه


ویژگی	شبکه تک‌لایه	شبکه چندلایه
لایه‌ها	فقط یک لایه خروجی	شامل لایه‌های ورودی، پنهان، و خروجی
توانایی مدل‌سازی	فقط مسائل خطی	مسائل خطی و غیرخطی
توابع فعال‌سازی	معمولاً خطی یا تابع پله‌ای	از توابع غیرخطی مانند سیگموید
کاربردها	ساده، مانند عملگرهای منطقی AND	پیچیده، مانند تشخیص الگو و پیش‌بینی
میزان محاسبات	کم	زیاد




لایه های شبکه عصبی (لایه ورودی)

■ لایه ورودی (Input Layer)

- * اولین لایه شبکه عصبی که داده های خام (ویژگی های ورودی) را از محیط خارجی دریافت می کند.
- * تعداد نورون های این لایه برابر با تعداد ویژگی های ورودی داده ها است.
- * این لایه فقط داده ها را بدون هیچگونه پردازشی به لایه های بعدی منتقل می کند.






لایه های شبکه عصبی (لایه مخفی)

■ لایه های مخفی (Hidden Layers)

- * میان لایه ورودی و لایه خروجی قرار دارند و پردازش و استخراج ویژگی های پیچیده را انجام می دهند.
- * ممکن است یک یا چند لایه مخفی در شبکه وجود داشته باشد که به نوع مسئله و طراحی شبکه بستگی دارد و به صورت تجربی تعیین می شود.
- * تعداد لایه های مخفی عمق شبکه عصبی را تعیین می کند. شبکه هایی با چندین لایه مخفی را شبکه های عصبی عمیق (Deep Neural Networks) می نامند.
- * تعداد زیاد نورون ها در لایه های مخفی ممکن است قدرت مدل را افزایش دهد اما در عین حال، خطر بیش برآزش (Overfitting) نیز وجود دارد.



لایه های شبکه عصبی (لایه خروجی)

■ لایه خروجی (Output Layer)

* آخرین لایه در شبکه است که مقادیر خروجی لایه های قبلی را پردازش کرده و خروجی قابل تفسیر تولید می کند.

* تعداد نورون های لایه خروجی به نوع مسئله بستگی دارد:


◀ در مسائل طبقه بندی دودویی (Binary Classification) و رگرسیون معمولاً ۱ نورون.

◀ در مسائل طبقه بندی چند کلاسه: تعداد نورون ها برابر با تعداد کلاس ها.

* در مسائل رگرسیون، خروجی معمولاً یک مقدار عددی است.

جمع بندی لایه های شبکه عصبی

ویژگی‌ها	نقش اصلی	لایه
تعداد نورون‌ها برابر با تعداد ویژگی‌های ورودی	دریافت داده خام و ارسال آن به لایه‌های بعدی	ورودی (Input)
تعداد و ساختار قابل تنظیم بر اساس مسئله	پردازش داده‌ها و استخراج روابط و ویژگی‌های پیچیده	مخفی (Hidden)
تعداد نورون‌ها بسته به نوع خروجی (طبقه‌بندی یا رگرسیون)	ارائه نتایج پیش‌بینی شده یا کلاس بندی شده به صورت نهایی	خروجی (Output)




پیش‌خور (Feedforward)

■ فرآیندی که در آن داده‌ها از لایه ورودی به لایه‌های مخفی (در صورت وجود) و سپس به لایه خروجی، بدون هیچ بازگشت یا حلقه‌ای در جریان داده‌ها، هدایت می‌شوند. در این فرآیند، هر نورون در هر لایه به نورون‌های لایه بعدی متصل است و داده‌ها از ورودی به خروجی جریان پیدا می‌کنند.

■ مراحل پیش‌خور:

- * دریافت ورودی‌ها
- * ضرب ورودی‌ها در وزن‌ها
- * جمع کردن نتایج
- * اعمال تابع فعال‌سازی
- * انتقال خروجی به نورون‌های لایه بعدی
- * خروجی نهایی




پیش‌خور (Feedforward)

■ اهمیت پیش‌خور در فرآیند آموزش

* در طول آموزش، پارامترهای وزن و بایاس بروزرسانی می‌شوند تا خروجی شبکه با مقدار واقعی (هدف) مطابقت بیشتری پیدا کند.

* پس از هر فاز پیش‌خور، خطا محاسبه شده و برای بروزرسانی وزن‌ها و بایاس‌ها در فاز پس‌انتشار (Backpropagation) استفاده می‌شود.


■ پیش‌خور یکی از مراحل اصلی در یادگیری و پیش‌بینی در شبکه‌های عصبی است و بدون آن، شبکه نمی‌تواند به خوبی عمل کند.



الگوریتم پس انتشار (Backpropagation)

- یکی از مهمترین روش‌ها برای آموزش شبکه‌های عصبی مصنوعی است.
- از مفاهیم گرادیان نزولی (Gradient Descent) و قاعده زنجیره‌ای (Chain Rule) برای محاسبه و بروزرسانی وزن‌ها و بایاس‌ها استفاده می‌کند.
- هدف اصلی پس انتشار، کاهش مقدار خطا یا تابع هزینه جهت پیش‌بینی‌های دقیق‌تر شبکه است.
- **مراحل:**

- * **پیش‌خور:** داده‌ها از ورودی به خروجی منتقل می‌شوند و خروجی پیش‌بینی شده ($\hat{y}$) تولید می‌شود.
- * **محاسبه خطا:** تفاوت بین خروجی پیش‌بینی شده ($\hat{y}$) و مقدار واقعی (y) محاسبه می‌شود.
- * **انتشار خطا به عقب:** گرادیان‌های خطا نسبت به وزن‌ها و بایاس‌ها محاسبه می‌شوند.
- * **بروزرسانی وزن‌ها:** وزن‌ها و بایاس‌ها با استفاده از گرادیان نزولی بروزرسانی می‌شوند.



نکات مهم الگوریتم پس انتشار (Backpropagation)

■ نکات مهم در پس انتشار:

* قاعده زنجیره‌ای (Chain Rule):

◀ پس انتشار از قاعده زنجیره‌ای استفاده می‌کند تا گرادیان خطا را نسبت به وزن‌ها و بایاس‌ها در هر لایه محاسبه کند.

* مقداردهی اولیه وزن‌ها:


◀ وزن‌ها در ابتدای آموزش معمولاً به صورت تصادفی مقداردهی می‌شوند. انتخاب مقدار مناسب می‌تواند در همگرایی بهتر و سریع‌تر مؤثر باشد.

* تابع فعال‌سازی:

◀ انتخاب تابع فعال‌سازی مناسب مانند Sigmoid یا ReLU یا Tanh نقش کلیدی در محاسبه گرادیان‌ها دارد.

* مشکل گرادیان ناپدید شونده (Vanishing Gradient):

◀ در شبکه‌های عمیق، گرادیان ممکن است در حین انتقال به لایه‌های اولیه کاهش یابد. این مشکل می‌تواند یادگیری شبکه را کند یا متوقف کند.




مزایا و چالش‌های الگوریتم پس‌انتشار (Backpropagation)

■ مزایا:

- * بهینه‌سازی مؤثر وزن‌ها و بایاس‌ها.
- * کاربرد گسترده در آموزش شبکه‌های عصبی عمیق.

■ چالش‌ها:

- * **گرادیان ناپدید شونده یا انفجاری:** در شبکه‌های بسیار عمیق، گرادیان ممکن است خیلی کوچک یا بزرگ شود.
- * **نیاز به تنظیم دقیق نرخ یادگیری:** نرخ یادگیری باید به دقت انتخاب شود.
- * **تکیه بر داده‌های برچسب دار:** پس‌انتشار نیاز به داده‌های آموزشی با برچسب دارد.



خطا یا تابع هزینه (Loss Function)

■ معیاری است که نشان می‌دهد پیش‌بینی‌های شبکه تا چه اندازه با مقادیر واقعی (Labels) فاصله دارند. تابع هزینه معمولاً یک مقدار اسکالر است و به صورت ریاضی بیانگر میزان خطا در پیش‌بینی‌ها است.

■ نمونه‌هایی از توابع هزینه

MSE (Mean Squared Error) *


◀ برای مسائل رگرسیون

Cross-Entropy Loss *

◀ برای مسائل طبقه‌بندی

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

$$Loss = -\frac{1}{n} \sum_{i=1}^n y_i \cdot \log(p(y_i)) + (1 - y_i) \cdot \log(1 - p(y_i))$$



الگوریتم گرادیان نزولی (Gradient Descent)

■ هدف یادگیری در شبکه‌های عصبی کاهش خطاست که از طریق روش‌های بهینه‌سازی مانند گرادیان نزولی (Gradient Descent) انجام می‌شود.


■ گرادیان نزولی یک روش تکراری است که به شبکه کمک می‌کند طی فرآیند زیر، مقدار تابع هزینه را با بروزرسانی وزن‌ها و بایاس‌ها کاهش دهد.

* **محاسبه گرادیان (شیب):** گرادیان نشان دهنده میزان تغییر تابع هزینه نسبت به هر وزن است $\frac{\partial L}{\partial \omega}$

* **بروزرسانی وزن‌ها:** وزن‌ها به سمت عکس شیب حرکت می‌کنند
$$\omega = \omega - \eta \frac{\partial L}{\partial \omega}$$

◀ η نرخ یادگیری (Learning Rate) است.

* **تکرار:** این فرآیند برای هر وزن در شبکه تکرار می‌شود تا زمانی که تابع هزینه به مقدار مطلوبی برسد.




نرخ یادگیری (Learning Rate)

■ یک مقدار عددی کوچک است که اندازه گام‌ها را در فرآیند گرادیان نزولی کنترل می‌کند.

■ اهمیت:

* اگر نرخ یادگیری خیلی بزرگ باشد، شبکه ممکن است از مینیمم محلی عبور کند و همگرا نشود.

* اگر نرخ یادگیری خیلی کوچک باشد، فرآیند یادگیری کند می‌شود.



انواع گرادیان نزولی ساده

■ Stochastic Gradient Descent (SGD)


- * از یک نمونه (یک داده) برای محاسبه گرادیان استفاده می‌کند.
- * **مزایا:** سریع‌تر است و حافظه کمتری نیاز دارد.
- * **معایب:** نوسان زیادی دارد و ممکن است بهینه محلی پیدا شود.

■ Batch Gradient Descent

- * از کل داده‌های آموزشی برای محاسبه گرادیان استفاده می‌کند.
- * **مزایا:** دقیق‌تر است.
- * **معایب:** محاسباتی سنگین برای دیتاست‌های بزرگ.

■ Mini-Batch Gradient Descent

- * از گروه‌های کوچکی از داده‌ها استفاده می‌کند.
- * **مزایا:** ترکیب مزایای دو روش قبلی.



انواع گرادیان نزولی بهبود یافته

■ Momentum

* **مشکل:** در گرادیان نزولی ساده، ممکن است شبکه در مینیمم محلی گیر کند یا به کندی به هدف برسد.

* **راه حل:** شتاب (Momentum) به گرادیان نزولی اضافه می شود تا شبکه بتواند از مینیمم محلی عبور کند و سریع تر همگرا شود.

■ RMSProp (Root Mean Square Propagation)

* **مشکل:** در مسائل پیچیده، اندازه گرادیان ها ممکن است در طول آموزش بسیار متفاوت باشد.


* **راه حل:** اندازه گرادیان ها را با استفاده از مقادیر میانگین مربع گرادیان نرمال سازی می کند.

■ Adam (Adaptive Moment Estimation)

* یکی از قدرتمند ترین و پُر کاربرد ترین الگوریتم های بهینه سازی است که ترکیبی از دو روش قبلی است.

مقایسه روش های گرادیان نزولی

روش	مزایا	معایب
BGD	ساده و قابل فهم	محاسباتی سنگین برای داده های بزرگ
SGD	سریع و کم حافظه	نوسانات زیاد
Mini-Batch	تعادل بین دقت و سرعت	وابسته به اندازه دسته
Momentum	بهبود سرعت همگرایی و عبور از مینیمم محلی	ممکن است پیچیدگی محاسباتی افزایش یابد
RMSProp	تنظیم خودکار اندازه گام ها	ممکن است در برخی مسائل تنظیم بیش از حد رخ دهد
Adam	ترکیب مزایای Momentum و RMSProp	نیاز به تنظیم آبر پارامترها



انتخاب بهترین روش گرادیان نزولی

■ انتخاب روش بهینه‌سازی بستگی به موارد زیر دارد:

* اندازه داده:


- ◀ برای دیتاست‌های کوچک، Gradient Descent مناسب است.
- ◀ برای دیتاست‌های بزرگ، Mini-Batch یا Adam بهتر عمل می‌کنند.

* نوع مسئله:

- ◀ مسائل طبقه‌بندی و رگرسیون پیچیده: Adam
- ◀ مسائل با تغییرات گرادیان شدید: RMSProp


* محاسبات:


- ◀ اگر سخت‌افزار محدود باشد، روش‌های سبک‌تر مانند SGD یا Mini-Batch پیشنهاد می‌شود.



فرآیند کلی آموزش شبکه عصبی

پیش خور (Feedforward)





سؤال؟