

## Interconnection Networks for Deep Neural Network Accelerators

شبکه های اتصال متقابل برای شبکه عصبی عمیق شتاب دهنده ها

## مقدمه

- مزایای قابل توجه AI منجر به پیشرفت در بسیاری از برنامه های دنیای واقعی ، مانند تشخیص گفتار و طبقه بندی تصویر شده است.
- از تعداد نورونهایی که به صورت الیه ای مرتب شده اند تشکیل شده است:
- لایه ورودی ، لایه های مخفی و لایه خروجی.
- در حال حاضر در شبکه های عصبی CNN به طور گسترده ای از DNN ها استفاده می شود ، یک نورون اساساً یک کار ساده را انجام می دهد:
- عمل جمع کردن ضرب MAC
- از طریق این اتصالات ، خروجی های یک لایه به ورودی های لایه تبدیل می شوند تا زمانی که نتیجه در لایه خروجی بدست آید.
- DNN ها دو مرحله دارند: آموزش و استنباط
- در مرحله آموزش مدل DNN با استفاده از برخی از داده های آموزش ایجاد می شود .
- در مرحله استنباط ، از مدل آموزش دیده ، برای ساخت یک پیش بینی استفاده می شود.


## ادامه مقدمه

- مراحل آموزش و استنباط چندین مرحله دارد ویژگی های مشترک ، اما تفاوت های اساسی معماری بین آنها وجود دارد.
- هدف اصلی آموزش به حداقل رساندن زمان لازم برای همگرایی با یک دقت خاص است ، یعنی مربوط به توان عملیاتی سیستم است.
- آموزش معمولاً برای دستیاری به توان عملیاتی بالاتر در چند گره یا حتی چندین خوشه به مقیاس کوچک و کوچکتر تبدیل می شود .
- برای استنباط ، تأخیر به اندازه توان تولید مهم است.
- در حالی که دقت برای استنباط نیز مهم است ، این یک روش معمول در برخی برنامه های کاربردی برای صحت معامله و کارایی بیشتر با پایین تر تأخیر است.
- تفاوت بنیاز به حافظه تفاوت بین آموزش و استنباط است.
- استنباط فقط آخرین را ذخیره می کند یعنی لایه فعال سازی در حالی که آموزش تقریباً باید همه آنها را ذخیره کند. فعال سازی تمام لایه ها برای محاسبه شبیه ها در جریان انتشار آن.
- دستگاه ها ، برای اجرای عملیات گسترده DNN به سیستم عامل های سخت افزاری قدرتمند نیاز دارند. با این وجود DNN های مقیاس پیزrk فعالی شامل ارتباطات پیچیده ، محاسبات گسترده و نیاز های ذخیره سازی ، که فراتر از توانایی دستگاه های جاسازی شده محدود کننده منابع مبتنی بر عناصر پردازش CPU و GPU برای اهداف عمومی است.
- این منجر به محبوبیت فزاینده اخیر در توسعه خاص دامنه سیستم عامل های محدودیت منابع با پردازش اختصاصی ، حافظه و منابع ارتباطی برای محاسبه DNN شده است.

## چالش مسئله

- توجه به ویژگی ذاتی محاسبه موازی در عملیات **DNN**، بهره برداری از چند هسته موازی بصری سخت افزار برای سرعت بخشیدن به عملیات است.
- بنابراین، برنامه طراحی مدارهای مجتمع خاص **ASIC** یک روش محبوب برای سرعت بخشیدن به محاسبات **DNN** در دستگاه های لبه ای است.
- به خاطر اینکه جریان داده منظم در عملیات **DNN**، اتصال بین آرایه ای معمولا در بیشتر شبکه های **DNN** مدرن استفاده می شود. به چالش کشیدن به عنوان مدل **DNN** عمیق تر می شود.
- در نتیجه، بسیاری از توسعه دهندگان به استفاده از **GPU-FPGA 6** یا بسیاری از پردازنده های مرکزی برای محاسبه عملیات **DNN** در مقیاس بزرگ فکر می کنند. عملکرد کلی، مبتنی بر **FPGA** هنوز هم از تأخیر دسترسی به حافظه طولانی رنج می برد.

# ترتیب زمانی کاره



# معایب و مزایا

- شبکه دهنده های مبتنی بر معماری فضایی که پدید آمده اند برای کنار آمدن با نیازهای محاسباتی گسترده DNN ها ، مشکل از صدھا PE است که می تواند برای رسیدن به مقدار زیاد سطح موثری محاسباتی استفاده شود.
- مشکل مشترک با این شبکه دهنده ها استفاده از جنھه های معمولی توپولو مانند بامس و مش است که قادر به کارآیی نیستند .
- تراشه (NoC) برای بهینه سازی فقط ارتباطات داخلی در داخل یک لایه است از این رو ، آنها فقط از الگوهای ثابت گردش داده پشتیبانی می کنند و در صورت خودسرانه بودن منجر به کم استفاده شدن منابع محاسباتی می شود.
- واحد جابجایی به تقسیم DRAM پنهانی باند به هر پورت باریک با انتقال داده ها در عوض استفاده از مالتی پلکسر کمک می کند.
- از این رو ، استفاده از منابع FPGA در حالی که DRAM کاهش می پابد و مسیریابی ساده تر می شود
- استفاده از پنهانی باند دست نخورد باقی می ماند. تنها عیب این معماری جدید یک افزایش مداوم ناچیز است تأخیر نسخه می تواند برای هر دو موثر باشد.
- مزایا:
- شبکه های عصبی عمیق DNN مزایای قابل توجهی در بسیاری از حوزه ها مانند شناخت مجدد الگو ، پیش بینی و بهینه سازی کنترل نشان داده است.
- انگیزه انواع سیستم عامل های محاسباتی برای تسريع در عملیات DNN تقاضا در عصر اینترنت اشیا شده است.
- از طرف دیگر ، با اتصال انعطاف پذیر ، DNN شبکه دهنده می تواند جریان محاسباتی مختلفی را پشتیبانی کند که انعطاف پذیری محاسبات افزایش می یابد.

## نتیجه

- با تکثیر NNها و به خصوص DNNها ، طراحی شتاب دهنده های سخت افزاری برای آنها رونق دارد. برای پیشرفت
- عملکرد و استقرار انعطاف پذیر DNNها ، قابل تنظیم است
- طرف دیگر ، اتصال *interconnect* با طرح های مختلف توپولو در طراحی DNN پیشنهاد و مورد نوجه قرار گرفت. از طراحی همچنین در محاسبات نوظهور بیشتر مورد توجه قرار گرفته است.
- پارادایمی مانند پردازش حافظه نزدیک / در حال اجرا که هدف آن چالش دیوار حافظه را تسخیر کند.
- برای جلوگیری از گلوبال شدن اتصال اینترکون در چنین محاسباتی پارادایم ها ، نیاز به طراحی های پیشرفتی تری دارد که می توانند یهندگان باند بسیار بالا برای ارتباط بین عناصر مختلف شتاب دهنده های NN، فناوری های نوظهور مانند اتصال بی سیم و نوری نیز می توانند برای مقابله با معایب سیم معمولی ارتباطات متقابل به کار گرفته شود.