

Mer lätthanterlig träning av bildgenererande AI

Författare: Oskar Larsson

Populärvetenskaplig sammanfattning av: *Robustness, Stability and Performance of Optimization Algorithms for GAN Training*

Om man går in på hemsidan thispersondoesnotexist.com får man se bilder på människor som inte existerar – ett datorprogram har genererat dem. Dessa datorprogram, som kallas GANs, kan lära sig att generera helt unika och felfria exempel på saker om vi bara ger dem en mängd exempel att utgå ifrån först. De kan lära sig att skapa allt möjligt: ansikten, musik och till och med proteinmolekyler¹. Men det finns ett stort problem med GANs: de är inte så lätta att jobba med och det kan vara dyrt och krävas väldigt mycket datorkraft för att uppnå bra resultat. I detta examensarbete har metoder utvärderats som kan göra det billigare och effektivare att skapa GANs.

För att förstå varför det är extra kostsamt att skapa GANs måste man veta lite om hur de fungerar. Man kan säga att en GAN innehåller två olika AIs som tävlar mot varandra för att lära sig. Men att träna två AIs är svårare än en. Det är nämligen viktigt att tävlingen är balanserad och att ingen dominerar matchen så att den andra inte får en chans att förbättras. För att få till den balansen krävs omfattande preliminära sökningar av inställningar för båda AIs innan man hittar några som fungerar. Först då kan man starta den faktiska träningen som man vill köra.

När GANs uppfanns tog man algoritmer som var anpassade för att bara träna en AI individuellt, och gav dem till två AIs samtidigt och lät dem tävla. I detta arbete har istället algoritmer som är speciellt utformade för tävlingsproblem utvärderats. Dessa metoder kan man säga låter de tävlande ha ett större samspel och låter de reagera på varandras drag vid varje tur. Både dessa tävlingsanpassade algoritmer och de algoritmer som vanligtvis används för GANs testades systematiskt med massvis av olika inställningar i experimenten för detta examensarbete.

Det visade sig i de prövade scenariona att de tävlingsanpassade algoritmerna gjorde bra ifrån sig väldigt ofta, till skillnad från de vanliga algoritmerna som bara gjorde bra ifrån sig för vissa specifika inställningar. Det betyder att dessa algoritmer kan göra det lättare att få till lyckad GAN träning utan att man behöver leta så mycket efter bra inställningar. Då behöver man inte spendera så mycket tid på preliminära experiment och kan spendera sin tid och datorbudget på att få resultat man kan använda.

¹ https://en.wikipedia.org/wiki/Generative_adversarial_network#Applications