

Formidlingstekst - PhD Cup 2026

Andreas Nygaard

Hvad nu hvis kosmologiske beregninger, der normalt tager uger eller måneder, kunne udføres på få minutter – uden at miste videnskabelig præcision?

I min forskning har jeg udviklet metoder, der gør netop dette muligt ved hjælp af kunstig intelligens. Ved at lade kunstige neurale netværk efterligne tunge kosmologiske beregninger kan vi udforske Universets grundlæggende egenskaber langt hurtigere end før. Det ændrer ikke blot, hvordan vi bestemmer Universets alder, indhold og udvikling – det reducerer også drastisk den beregningskraft og energi, som moderne kosmologisk forskning ellers kræver. Det åbner for nye måder at lave forskning på, både i kosmologi og i en lang række andre videnskaber, hvor tunge statistiske metoder i dag sætter tempoet.

At forstå Universet er et puslespil

Universet er enormt. Afstandene til fjerne galakser er næsten ufattelige, og alligevel kan vi beregne både Universets alder og dets sammensætning. For at undersøge Universets hemmeligheder har vi brug for to solide grundpiller. Den ene er observationer og data, som indsamles med enorme teleskoper og instrumenter både på Jorden og i rummet, mens den anden er teoretiske modeller baseret på vores forståelse af fysikkens love, såsom Einsteins generelle relativitetsteori, der beskriver de største strukturer, og kvantemekanikken, der beskriver de mindste.

Opgaven er at sammenligne observationer med modeller, der kan forudsige tilsvarende observationer. I praksis er dette ofte som at lede efter en nål i en høstak: muligt, men ekstremt tidskrævende. For at finde den model, der bedst matcher observationerne, må man afprøve hundredtusinder til millioner af forskellige parameterkonfigurationer. Til dette anvendes typisk den såkaldte Markov chain Monte Carlo (MCMC)-metode, hvor man systematisk udforsker parameterrommet for at finde de områder, der stemmer bedst overens med data. Da et enormt antal modeller skal beregnes, er beregningstiden afgørende. Nogle typer af modeller kan beregnes på sekunder, mens andre kræver dage på store supercomputere. Selv når en enkelt model kun tager omkring ét sekund, kan den samlede analyse nemt tage uger, fordi processen kræver så mange gentagelser.

Selvom vores nuværende teorier kan forklare en stor del af de kosmologiske observationer, er der stadig fænomener, som ikke kan beskrives fuldt ud. Derfor består en stor del af moderne kosmologisk forskning i at teste udvidelser af vores teorier op mod stadig mere præcise observationsdata. I takt med at nye eksperimenter leverer data af hidtil uset kvalitet, vokser behovet for gentagne og omfattende MCMC-analyser. Den tunge beregningstid udgør dermed en reel flaskehals for, hvor hurtigt forskningen kan bevæge sig fremad.

Kunstig intelligens som genvej gennem Universet

Efter selv at have anvendt mange langsommelige MCMC-processer stod det klart for mig, hvor meget ventetid den konventionelle tilgang medfører, og hvor meget det bremsede mit ph.d.-projekt. Jeg kunne se frem til flere år med en arbejdsproces, der kun ville blive langsommere i takt med, at modellerne blev mere avancerede og beregningstunge.

Samtidig har kunstig intelligens i de seneste år udviklet sig eksplosivt, og her opstod en oplagt mulighed. Min forskning skiftede derfor retning mod at anvende kunstige neurale netværk til at gøre kosmologiske beregninger hurtigere og mere effektive. De neurale netværk kan trænes til at efterligne resultatet af en egentlig modelberegning på en brøkdel af tiden. Dermed kan den ellers langsommelige proces med at finde den bedst passende model reduceres dramatisk. Hvad der før tog uger eller måneder, kan nu klares på få minutter.

En central del af mit arbejde har været at gøre disse neurale netværk så præcise og effektive som muligt. Her spiller træningsdata en afgørende rolle: Et neuralt netværk kan kun blive så godt som de data, det trænes på. Træningsdataene består af faktiske modelberegninger, og det kan derfor virke fristende blot at beregne så mange som muligt. Men hvis mængden af træningsdata nærmer sig det antal beregninger, en konventionel MCMC-proces kræver, forsvinder fordelene ved netværket.

I stedet har jeg udviklet en metode, hvor træningsdata udvælges strategisk. Modeller, der er helt uforenelige med observationerne, udelades, så netværket kan fokusere på de områder af parameterummet, der faktisk er relevante. Dette har ført til udviklingen af en algoritme, der iterativt og automatisk indsamler nye træningspunkter baseret på deres relevans i forhold til data. Resultatet er en fleksibel og generel metode, der kan anvendes langt bredere end blot inden for kosmologi – i alle forskningsfelter, hvor MCMC-metoder spiller en central rolle.

Hurtigere forskning – og nye perspektiver

Med introduktionen af hurtige neurale netværk åbnes der for metoder, som tidligere har været urealistiske i kosmologisk parameterbestemmelse. Netværkene er mange størrelsesordener hurtigere end traditionelle modeller og har en simpel og velkontrolleret struktur, der muliggør mere effektive statistiske metoder og hurtigere konvergens. Dette gør det muligt at udnytte observationer langt mere effektivt samt at anvende nye metoder, der tidligere har været begrænset af beregningsmæssige hensyn.

Ud over de metodiske fordele har dette også et bredere samfundsperspektiv. I takt med at datamængder og modelkompleksitet vokser, bliver beregningskraft en stadig vigtigere – og ofte overset – ressource i forskningen. Konventionelle MCMC-analyser kan tage uger og kræver store mængder regnekraft og elektricitet. Bare inden for kosmologi svarer det samlede energiforbrug af MCMC-analyser på verdensplan til niveauet for en mellemstor by, hvilket medfører et betydeligt CO₂-aftryk. Selvom kosmologi ikke er den største bidragsyder til verdens samlede energiforbrug, peger denne udvikling på et bredere princip: mere intelligente algoritmer kan føre til både hurtigere og mere bæredygtig forskning. Ved at erstatte dyre modelberegninger med datadrevne approximationer kan man drastisk reducere både beregningstid og energiforbrug – uden at gå på kompromis med præcisionen.

Et konkret eksempel på dette potentiale findes inden for epidemiologi. Under COVID-19-pandemien blev MCMC-metoder og andre statistiske modeller anvendt til at estimere smitteparametre og forudsige sygdomsudbredelse baseret på løbende data. Hurtigere analysemetoder kan betyde, at beslutninger om sundhedstiltag kan træffes rettidigt, hvilket har direkte konsekvenser for folkesundhed. Ved at erstatte tunge simulationsbaserede modeller med neurale netværk, som emulerer de samme beregninger, kan man gennemføre analyser betydeligt hurtigere. Samme problemstilling findes i lægemiddeludvikling, hvor statistiske modeller bruges til at vurdere effekten og sikkerheden af nye stoffer, samt i klimaforskning, hvor komplekse modeller skal afprøves mod store datamængder. I alle disse tilfælde er der et fælles mønster: tunge beregninger begrænser tempoet. Ved at overføre de metoder, jeg har udviklet i en kosmologisk kontekst, kan man derfor potentielt accelerere forskningsprocesser på tværs af discipliner og gøre avancerede analyser mere tilgængelige.

Fremtidens kosmologi vil være præget af endnu større datamængder og mere præcise observationer fra næste generation af eksperimenter. For at udnytte det fulde potentiale heraf, bliver det afgørende, at vores analysemetoder kan følge med. Her spiller kunstig intelligens en central rolle, ikke som en erstatning for fysisk forståelse, men som et redskab til at anvende denne forståelse i praksis.

Min ph.d.-forskning bidrager til denne udvikling ved at vise, hvordan neurale

netværk kan integreres direkte i statistiske analysemetoder og dermed ændre den måde, vi udfører kosmologisk parameterbestemmelse på. Samtidig åbner det for en bredere diskussion om, hvordan vi designer fremtidens forskningsworkflow med fokus på hastighed, præcision og ansvarlig anvendelse af ressourcer. Kunstig intelligens vil uden tvivl fortsætte med at udvikle sig, og det bliver spændende at udforske, hvordan disse metoder kan bringe os endnu tættere på at forstå Universets fundamentale natur.