

Jan Kortenhoeven

Arkeologi og kunstig intelligens: En undersøkelse av teknologiens muligheter og begrensninger

Bacheloroppgave i Arkeologi

Veileder: Martin Callanan

Mars 2023



Jan Kortenhoeven

Arkeologi og kunstig intelligens: En undersøkelse av teknologiens muligheter og begrensninger

Bacheloroppgave i Arkeologi
Veileder: Martin Callanan
Mars 2023

Norges teknisk-naturvitenskapelige universitet
Det humanistiske fakultet
Institutt for historiske og klassiske studier



Kunnskap for en bedre verden

1	Introduksjon	1
2	Grunnleggende definisjoner	2
2.2	Kunstig Intelligens (AI)	2
2.3	Maskinl�ring (ML)	3
2.3.1	Dyp l�ring & nevralt nettverk (deep learning & neural networks)	3
2.3.2	Overv�ket l�ring (supervised learning)	5
2.3.3	Uoverv�ket l�ring (unsupervised learning)	5
2.3.4	Forsterket l�ring (reinforced learning)	6
2.3.5	Overf�ringsl�ring (transfer learning)	6
3	Forskningshistorie	7
4	Eksempler p� moderne bruk	9
4.1	Bildeanalyse - artefaktklassifisering og analyse	9
4.2	AI-stedsposisjonsprediksjon	11
4.3	Bevaring av kulturminner	13
4.4	Epigrafi og spr�k	14
4.5	aDNA analyse	15
4.6	Kampen mot ulovlig plyndring og handel med kulturarv	15
4.7	Simulering av historiske og forhistoriske samfunn & formidling	16
4.8	3D-modellering og rekonstruksjon	17
5	Diskusjon	20
5.1	Fordeler	20
5.2	Utfordringer og begrensninger	21
5.3	Etske hensyn	21
6	Konkluderende tanker	22
	Figurliste	23
	Kilder (1058 sider)	24

1 Introduksjon

Som vitenskapsfelt er kunstig intelligens (engelsk: *artificial intelligence [AI]*) opptatt av å forstå og skape intelligente enheter. Disse enhetene har anvendelser innen nesten alle tradisjonelle fagområder, og er allerede i bruk mye. Hver gang du skriver inn et søk i Google eller en annen søkemotor, finner en AI algoritme millioner av resultater i løpet av millisekunder, og rangerer disse resultatene i rekkefølge etter relevans for søket ditt; relevansen beregnes ut ifra på ditt personlige datasett, som baseres på tidligere søk, lokasjon, og andre datapunkt som kan hentes gjennom informasjonskapsler (Nayak, 2022). Når man ser en moderne bil kjørende på E6 bruker den sannsynligvis avansert cruisekontroll AI til å holde seg til fartsgrensen og X antall meter unna bilen framfor. Kunstig intelligens beskrives som et av de raskest voksende feltene i verden, og genererer over en milliard amerikanske dollar per år (Russell & Norvig, 2020, kap. 1).

Innen arkeologi har AI potensialet til å revolusjonere nesten alle aspekter av feltet. Gjennom denne teksten vil jeg utforske caser som utgjør startfasen av denne revolusjonen. Jeg har valgt en eller noen få casestudier i hvert av disse emnene:

- Gjenkjenning av gjenstander og automatisk klassifisering etter typologi
- Forutsigelse av arkeologisk sted gjennom mønstergjenkjenning og luftbilder og AI-modeller
- Bevaring av kulturarv
- Naturlig språkbehandling og geolokalisering basert på dialekt
- DNA-analyse
- Bekjempe ulovlig plyndring og handel med kulturarv
- Simulering av historiske og forhistoriske samfunn for formidlingsformål og avdekking av ny arkeologisk kunnskap
- 3D modellering og rekonstruksjon av arkeologiske funn og steder

Jeg vil kort diskutere disse casestudiene, gjennomgå hvordan AI-modellene i de trenes og hvordan de presterer. Ved å bruke casestudier og to bøker om AI som et grunnlag, har denne studien som mål å fremheve de ulike måtene kunstig intelligens brukes på i arkeologi, samtidig som den tar for seg utfordringene, begrensningene og etiske dilemmaene som dukker opp som et resultat av dens integrering i feltet.

2 Grunnleggende definisjoner

For å forstå temaene som dekkes i denne teksten, er det viktig å ha et grunnleggende grep på terminologien og metodikken til AI-forskning; dette kapitlet vil dekke alt som er relevant for oppgaven. For det første må kunstig intelligens (AI) og maskinlæring (ML) skilles fra hverandre, da disse ofte brukes om hverandre (*Russell & Norvig, 2020, kap 1*). Selv om disse konseptene henger sammen, er ML en gren av AI. AI er opptatt av å skape intelligente systemer som er i stand til å løse oppgaver som normalt vil kreve menneskelig intelligens. Noen eksempler på dette er transport, språkoversettelse eller digitale personlige assistenter (*European Parliament, 2020*). Det er mange måter å lage AI systemer på; en av de mest effektive måtene er ML (*Russell & Norvig, 2020, kap 1.2.6*). ML er en metode som brukes for å trene opp programmer til å fullføre visse oppgaver. Bedriften OpenAI er i fronten av disse nye teknologiene med DALL-E 2 og ChatGPT, men Google og andre store dataselskaper gjør også store fremstøt i markedet, som stadig blir mer konkurransedyktig. I dette kapitlet vil jeg dekke hvordan AI blir definert, og forklare enkelt hvordan man kan bruke ML til å trene AI.

2.2 Kunstig Intelligens (AI)

I 1950 foreslo Alan Turing en test for å bedømme om en AI demonstrerer menneskelig intelligens gjennom samtale. Det er flere varianter av Turing-testen, men alle går omtrent som følger; to aktører har en samtale med hverandre, den ene vil være en AI, og den andre et menneske. De samtaler gjennom et tekstformat, som en evaluator vil observere. Maskinen består Turing-testen dersom evaluatoren ikke er i stand til pålitelig å skille maskinen fra mennesket (*Turing, 1950*). Selv om Turing-testen ikke lenger betraktes som en omfattende vurdering av om en maskin viser menneskelige nivåer av intelligens (*Joshi, 2020, s. 4*), er den fortsatt en verdifull målestokk for å vurdere en AI-modells språklige evner. Ameet V Joshi beskriver oppgaven til AI som så:

"[...] understanding human language, performing mechanical tasks involving complex manoeuvring, solving computer-based complex problems possibly involving large data in very short time and revert back with answers in human-like manner" (2020, s. 4)

Selv om Turing-testen ikke var en urimelig kvantifisering av hva som ble forventet av en AI i løpet av årene da den ble unnfanget på 1950-tallet, trenger ikke kunstig intelligens nødvendigvis å etterligne menneskelig intelligens. Det er noen likheter mellom et menneske og en maskin; det nevralt nettverket, men det er også mange ulikheter - maskiner lider ikke av sykdom, aldri eller noen av de andre fysiske plagene vi mennesker opplever, og de uttrykker seg selv ikke gjennom klær og kroppsspråk; de kan lære alt om oss, men de kan ikke være oss. I tillegg, mens moderne AI har evnen til å etterligne menneskelig tale nesten feilfritt, anses fortsatt ikke program som ChatGPT for å ha "menneskelig intelligens", selv når de kommuniserer på en menneskelig måte (*Goertzel, 2007, 6-8*).

I samtiden brukes ofte egne definisjoner for forskjellige "nivå" av kunstig intelligens:

- ANI (Artificial Narrow Intelligence): ANI refererer til AI-systemer som er designet for å utføre spesifikke oppgaver eller løse spesifikke problemer; disse kalles også

"weak AI". Disse systemene er begrenset til oppgavene de er spesielt designet for; eksempler på ASI-systemer er virtuelle assistenter (Siri, Google, Alexa), selvkjørende biler og programvare for bildegjenkjenning.

- AGI (Artificial General Intelligence): AGI refererer til AI-systemer som har evne til å lære og løse oppgaver på likt nivå som mennesker. Disse systemene kan tenke abstrakt, forstå komplekse ideer og tilpasse seg nye situasjoner. AGI blir noen ganger referert til som "sterk AI" eller "full AI." Foreløpig eksisterer det ingen AGI-systemer, men det er mange som jobber mot det. Noen mener at dette er det endelige målet for all AI-forskning (*Goertzel, 2007, s. 2-6*).
- ASI (Artificial Superintelligence): ASI refererer til AI-systemer som overgår menneskelig intelligens på alle måter. Disse systemene er i stand til å løse problemer som mennesker ikke engang kan forstå og kan potensielt forandre verden på dyptgripende måter. ASI blir noen ganger referert til som "superintelligent AI." Foreløpig finnes det ingen ASI-systemer, og det er ikke klart om det i det hele tatt er mulig å lage et. Noen eksperter har imidlertid advart om de potensielle farene ved ASI hvis den ikke er riktig utformet og kontrollert; automatisert overvåking, cybersikkerhet og dødelige autonome våpen (*Russell & Norvig, 2020, kap. 1.5*).

2.3 Maskinlæring (ML)

Arthur Lee Samuel definerte ML som studien om å gi datamaskiner muligheten til å lære å fullføre en oppgave uten å bli direkte programmert for det (*Mahesh, 2020, s. 381*). Grunnen til at du vil at en maskin skal lære av seg selv, i stedet for å programmere hver linje med kode selv, er fordi noen oppgaver er altfor komplekse til å løse med menneskeskrevet kode. For å eksemplifisere, la oss si at vi prøver å lage en maskin som kan gjenkjenne forskjellen mellom katter og hunder. Med tradisjonell programmering må det lages regler for hvordan det forventes at katter og hunder skal se ut – størrelse, form, farge, rase osv. Til syvende og sist vil dette være eksepsjonelt komplisert å manuelt skrive kode for, ikke bare på grunn av forskjellene mellom katte- og hunderaser, men også de individuelle egenskapene innenfor disse rasene som f.eks. fasett på ører, hode og kropp. Dessuten vil ikke belysningen eller kvaliteten på hvert datapunkt (bilde) være lik. I ML, i stedet for å skrive disse reglene manuelt, fortelles maskinen hva den ønskede outputen er. Vi mater deretter programmet med dataene våre (bilder av katter og hunder), og ber den lage reglene for å identifisere forskjellene selv. Selv om dette er en overforenkling, beskriver det ideen om ML. Det er dessuten et par forskjellige måter å trene en modell på; disse har alle sine egne bruksområder som de trives i. Mer komplekse modeller kan trenes ved å bruke flere av disse metodene. Dette underkapittelet er nøkkelen til å forstå de arkeologiske eksemplene jeg legger frem i kapittel tre til seks.

2.3.1 Dyp læring & nevrale nettverk (deep learning & neural networks)

Følger du utviklingen av AI og ML, vil du utvilsomt ha hørt om nevrale nettverk og dyp læring. Nevrale nettverk er veldig nært knyttet dyp læring, og det er derfor jeg dekker begge disse i samme punkt. Nevrale nettverk er løst basert på biologiske nevroner, som

fungerer på lignende måter. Et nevralt nettverk er en serie sammenkoblede noder; disse kalles nevroner. Forbindelsen mellom noen nevroner er sterkere enn andre, det er forskjellen i disse forbindelsene som gir oss forskjellig output basert på vår input; jeg går nærmere inn på dette når jeg forklarer *multilayer perceptron* nedenfor. For vårt eksempel med katter og hunder fra tidligere, vil input være bilder. Disse bildene kan deles inn i piksler, som har hver sin hex-verdi. Maskinen må lære forholdet mellom disse pikslene for å kunne gi en korrekt gjetning. Forholdet mellom piksler kan være en bestemt form: for eksempel en rett linje, en bøyd linje eller en sirkel. Figur 1 illustrerer hvilke trekk et nevralt nettverk kan identifisere som viktige for å forstå hva som er avbildet.



Figur 1 (Sanderson & Pullen, 2017)

Et typisk *multilayer perceptron* (MLP) nevralt nettverk består av tre typer lag. Jeg bruker MLP som eksempel fordi det er en veldig enkel variant av nevrale nettverk; jeg diskuterer mer kompliserte nevrale nettverk senere, men å forklare nøyaktig hvordan de fungerer er utenfor rammen av denne teksten.

1. Input layer - Det er her du legger inn dataene dine; det kommer an på hva du trener programmet til, men dette er ofte bilder eller tekst.
2. Hidden layer(s) - I dette trinnet kan det være et hvilket som helst antall lag, avhengig av funksjonen og kompleksiteten av oppgaven til nettverket. Hvert nevron i et gitt lag er typisk koblet til hvert nevron i dets tilstøtende lag. Nevronene har en *weight* og en *bias*; disse blir bestemt under trening. En *weight* er i hovedsak styrken til nevrale forbindelser; disse bestemmer hvor stor betydning eller innflytelse en nevron har på en annen, og er representert som en numerisk verdi. *Bias* er en offset-verdi som gir nettverket mer fleksibilitet; hvis vi for eksempel vil at et nevron bare skal være aktivt når summen av tilknyttede *weights* er over 5; lages det en *bias*. Dette er veldig enkelt forklart bare et tall du legger til ligningen for å få et ønsket resultat. For eksempel, i et nevralt nettverk som er opplært til å klassifisere bilder av katter og hunder, kan *bias*-begrepet hjelpe nettverket med å lære å skille mellom de to klassene, selv om input-bildene har forskjellig bakgrunn eller lysforhold. Ved å justere *bias* kan nettverket lære å produsere riktig output selv når inputen ikke er perfekt på linje med de forventede mønstrene.

3. Output layer - Dette laget er der programmet viser resultatet av sine beregninger. Dette er ofte en rekke tall som må settes sammen av et program for at vi skal hente ut nyttig informasjon (*Sanderson & Pullen, 2017*).

Begrepet dyp læring brukes når det er snakk om et nevralt nettverk som er dypt og har mange lag. Som tidligere nevnt finnes også mer komplekse variasjoner enn MLP. I dagens populærkultur er *convolutional neural networks* (CNN) og *transformer neural networks* (TNN) sentrale. CNN-er er typisk brukt for å håndtere bildebehandling og klassifisering. TNN-er er egnet for naturlig språkbehandling (NLP) og dataanalyse (*Russell & Norvig, 2020, kap. 23.1.7*).

2.3.2 Overvåket læring (supervised learning)

Overvåket læring er en måte å lære et dataprogram å lage spådommer basert på merkede data som har både input og output variablene allerede. Hvis du for eksempel har en samling av flintartefakter med forskjellige former, størrelser og bruksområder, kan du bruke dem som data for å trene opp en ML-modell. Inputen vil være bilder og/eller egenskapene til flintartefaktene (lengde, bredde, tykkelse) og outputen vil være kategorien til flintartefaktene (øksehoder, pilspisser, skrapere). Modellen vil lære å assosiere inputen med outputen ved å se på mange eksempler av flintartefakter som har blitt merket med deres kategori. Dette kalles treningsdata. Når modellen er trent, kan den forutsi kategorien til en hvilken som helst ny flintartefakt basert på dens egenskaper. Målet med overvåket ML er å lage nøyaktige spådommer på nye data som ikke har blitt sett før av modellen. For å evaluere hvor godt modellen presterer, kan vi sammenligne dens spådommer med den faktiske kategorien til testdataene og beregne nøyaktighet eller presisjon (*Joshi, 2020, 10*). Om modellen ikke er nøyaktig nok, kan den trenes på flere data som vil videre justere *weight* og *bias*.

2.3.3 Uovervåket læring (unsupervised learning)

Uovervåket læring er en type ML der algoritmen ikke er lært opp med merkede data. Algoritmen må i stedet identifisere mønstre og sammenhenger i dataene på egen hånd. Et arkeologisk eksempel på uovervåket læring kan være analyser av keramikkfragmenter. Arkeologer finner ofte store mengder knust keramikk på utgravningssteder, noe som kan gi verdifull informasjon om kulturen og praksisen til menneskene som bodde der. For å analysere keramikkfragmentene ved å bruke uovervåket læring, kan vi bruke "clustering" algoritmer for å gruppere lignende fragmenter sammen basert på egenskaper som materiale og dekorasjon. Algoritmen vil analysere egenskapene til hvert fragment og gruppere dem sammen basert på likheter, uten noen forhåndseksisterende etiketter med kjent data. Uovervåket læring kan avsløre mønstre i keramikken som tidligere var ukjent, for eksempel bruken av visse former eller dekorasjoner til spesifikke formål eller i bestemte tidsperioder (*Joshi, 2020, 11*).

Generative Adversarial Networks (GAN) er en type uovervåket læring som bruker to nevralt nettverk for generative oppgaver som bildegenerasjon, og for arkeologi, gjenoppbygging av gjenstander. Et av nettverkene kalles generatoren; dette nettverket prøver å generere noe (vanligvis bilder) basert på treningsdataene deres. Det andre nettverket, kjent som diskriminatoren, prøver å identifisere de genererte dataene i et

sett med umerkede genererte og ikke-genererte (testing) data. Gjennom en inkrementell læringsprosess vil generatoren til slutt kunne generere data som diskriminatoren ikke kan skille fra testdataene (*Russell & Norvig, 2020, kap. 22.7.1*). Senere vil jeg dekke noen tilfeller der denne teknologien har blitt brukt til å rekonstruere gjenstander basert på frakturerte data (*se kap. 4.8*).

2.3.4 Forsterket læring (reinforced learning)

Forsterket læring er en type ML som involverer en agent som samhandler med et miljø for å lære en atferd som maksimerer et belønningssignal. I motsetning til overvåket og uovervåket læring, hvor agenten mottar eksplisitt tilbakemelding eller merkede data, må agenten lære gjennom prøving og feiling. I forsterket læring lærer agenten ved å utføre handlinger i et miljø og motta tilbakemelding i form av belønning eller straff. Dette er typisk representert som en skalarverdi, hvor for eksempel belønningen er +1 og straff er -1. Målet til agenten er å lære en tilnærming som maksimerer den kumulative belønningen den mottar over tid. Dette krever at agenten balanserer mellom utforskning og utnyttelse, hvor den må prøve nye handlinger for å lære mer om miljøet samtidig som den utnytter handlingene som har ført til positive resultater tidligere (*Russell & Norvig, 2020, kap. 22-22.2*). Dette er spesielt aktuelt når du lærer et program å spille et spill, eller å kjøre bil, hvor det må læres gjennom prøving og feiling. I arkeologisk sammenheng kan dette brukes til å simulere eldgamle samfunn (*se kap. 4.7*); dette vil kunne gi oss dypere innsikt i de forskjellige rollene og samspillet mellom dem.

2.3.5 Overføringslæring (transfer learning)

Et stort fremskritt innen AI som tillater den raske utviklingen i feltet er overføringslæring. I hovedsak er dette en samling metoder som gjør at en allerede opplært modell kan overføres for bruk i en annen lignende brukssituasjon. Et viktig eksempel er innenfor delfeltet naturlig språkbehandling (Natural Language Processing - NLP); NLP handler om å lære maskiner å kommunisere ved hjelp av naturlig språk (*Russell & Norvig, 2020, kap. 23-23.1*). Det finnes modeller (ELMo, GPT, BERT) som har blitt forhåndsopplært på massive tekstkorpus (som for eksempel Wikipedia), hvorfra de har fått forståelse for naturlig språk (*Ghati, 2020*). Ved å bruke overføringslæring kan disse modellene finjusteres for å hjelpe på en rekke felt som lingvistikk, kognitiv psykologi, nevrovitenskap og selvfølgelig arkeologi (*se kap. 4.4*). Å forstå naturlig språk lar AI lære og formidle fra humaniora sin enorme samling av informasjon (forskningsartikler, rapporter og casestudier) lagret gjennom naturlig språk.

3 Forskningshistorie

Det tverrfaglige forholdet mellom AI og arkeologi er i sin spede begynnelse, så for dette kapitlet er hovedfokuset mitt på AIs generelle forskningshistorie. Merk også at de fleste casene i kapittel 4 har publiseringsdatoer innen det siste tiåret; disse casene er grunnlaget for framtidig arkeologisk AI.

Dartmouth Summer Research Project on Artificial Intelligence fra 1956 er generelt anerkjent som starten på AI som forskningsfelt. I spissen for denne bevegelsen sto John McCarthy; og sammen med Marvin Minsky, Claude Shannon og Nathaniel Rochester foreslo de en åtte ukers workshop med 10 matematikere, data- og kognitive forskere. Målet med denne workshopen var å "finne hvordan man kan få maskiner til å bruke språk, danne abstraksjoner og konsepter, løse typer problemer som nå er forbeholdt mennesker, og forbedre seg selv" (*McCarthy et al., 1955*). Det som kom ut av denne workshopen var en retning for AI å jobbe mot. Siden den gang har det vært jevn og inkrementell fremgang på feltet, med noen bemerkelsesverdige sprang som da IBM sin DeepBlue slo stormester Kasparov i sjakk (1997), når AlphaGo slo Lee Sedol i spillet Go (2016) (*Russell & Norvig, 2020, kap. 1.3*), og mer nylig, program som MidJourney, og OpenAI sin DALL-E 2, GPT-3 og 4. Disse er offentlig tilgjengelig på [midjourney.com](https://www.midjourney.com) og openai.com, og jeg anbefaler å leke litt rundt med dem for å få en ide over hvor AI er i dag. Mens to eksempler handler om spill, bør man vurdere disse som benchmarks for kompleksiteten til AI i stedet for selve skrittet fremover.

Mens datastyrt arkeologi var et diskutert tema en tid tidligere, var Jim Doran en av de første som seriøst utforsket tverrfaglighet mellom AI og arkeologi i "Formal methods and archaeological theory: a perspective." (1986). I sin tekst diskuterer han ekspertssystemer; disse er dataprogrammer utviklet for å simulere beslutningstaking og problemløsningsevner til en menneskelig ekspert på et spesifikt domene. Disse systemene bruker AI-teknikker for å modellere en menneskelig ekspert og gi løsninger på komplekse problemer. Han nevner at en av hovedfordelene med ekspertssystemer innen arkeologi er deres evne til å håndtere store mengder data og komplekse sammenhenger mellom ulike variabler. Han påstår at dette kan være spesielt nyttig i situasjoner der tradisjonelle arkeologiske metoder kan slite med å analysere og tolke data, for eksempel når man arbeider med ufullstendige eller tvetydige bevis. Han slår fast at stor innhenting og systematisering av kunnskap i passende form har avgjørende betydning. Når han nevner "passende form", mener han lett lesbar for "ekspertsystemer". I samtiden er denne typen datainnsamling normen i arkeologisk praksis; vi bruker datastyrte systemer for å samle alt moderne eller fremtidige forskere kan finne interesse for. I tillegg er det lagt ned stor innsats i digitalisering av gamle arkeologiske rapporter; Jeg vil diskutere delvis automatisering av digitalisering og datautvinning fra begrensede rapporter senere i dette essayet.

For å avslutte dette kapitlet vil jeg diskutere hvorfor kunstig intelligens først nå blir populært brukt, generelt og i arkeologi. Som fastsatt av Jim Doran, kreves store samlinger av passende data av disse systemene; de siste to tiårene har vi samlet inn mer data enn vi kan behandle manuelt. Med tilgjengeligheten av store databaser med systematisert arkeologisk kunnskap, har forskning og utvikling av AI-plattformer blitt demokratisert. I tillegg har datakraften vokst eksponentielt de siste par årene. Tradisjonelt har grafikkbehandlingsenheter (GPU) blitt brukt til AI-formål, men siden de er designet for å kunne håndtere mange bruksområder, og trenger å støtte mange

forskjellige applikasjoner, er de ikke veldig økonomiske for bruk med AI. Det er her tensor prosesseringsenheter (TPU) virkelig har drevet feltet fremover; de ble utviklet av Google spesielt for å håndtere de beregningsmessige kravene til maskinlæring. De har brukt TPU-er internt siden 2015, men de har siden blitt offentlig tilgjengelig i 2018 ([OpenMetal, TPU Vs GPU: Pros and Cons](#)). Teknologier som dyp læring (*kap. 2.3.1*), forsterket læring (*kap. 2.3.4*) og overføringslæring (*kap. 2.3.5*) er også nøkkelpunkter i den nye utviklingen av AI.

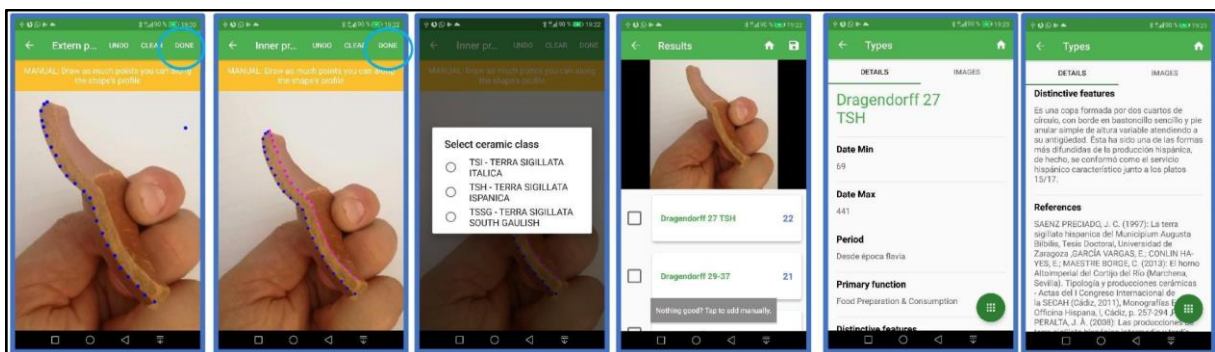
4 Eksempler på moderne bruk

I dette kapittelet vil jeg utforske flere arkeologiske anvendelser av AI og ML, alt fra bildegjenkjenning for artefaktklassifisering til simulering av eldgamle samfunn. I hvert underkapittel vil jeg fremheve relevante caser og artikler som viser potensialet og begrensningene til AI i arkeologi. Bruken av AI i arkeologi er fortsatt i startfasen, men mulighetene er spennende. Ettersom teknologien fortsetter å forbedre seg og mer data som er brukbar av AI blir tilgjengelig, kan vi forvente at AI blir et stadig viktigere verktøy innen arkeologi. Det er derimot viktig å erkjenne at AI ikke er en erstatning for tradisjonelle arkeologiske metoder, men snarere en komplementær tilnærming som kan effektivisere og forbedre vår evne til å tolke og analysere arkeologiske data. AGI (se kap. 2.2) som menneskelig erstatning er et interessant diskusjonstema, som jeg vil utforske mer detaljert i kapittel 5.

4.1 - Bildeanalyse - artefaktklassifisering og analyse

ArchAIDE, som står for "Archaeological Automatic Interpretation and Documentation of cERamics", et prosjekt finansiert av EUs Horizon 2020 forsknings- og innovasjonsprogram, er et system utviklet for å støtte automatisk gjenkjenning av arkeologisk keramikk fra utgravninger rundt om i verden. ArchAIDE-appen kan lastes ned

på mobile enheter (NB: appen er ikke under aktiv utvikling lengre, og støtter ikke nyere versjoner av Android). Ved å bruke appen til å ta et bilde av et keramikkskår og tildele alle kjente attributter manuelt, vil det gi ut ukjente attributter som f.eks. typologien (fig. 2).

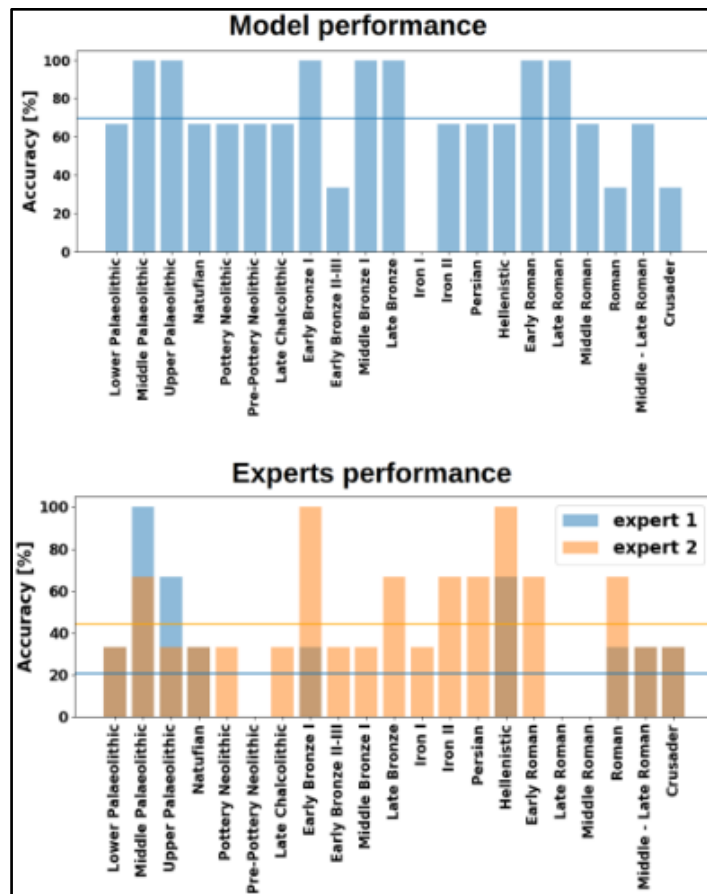


Figur 2 (Anichini et al., 2020)

Applikasjonen er bygget rundt et sett med to databaser, en referansedatabase og en resultatdatabase. Referansedatabasen kombinerer digitale og papirkataloger over keramikktypologier som opplæringsdata; dette gir systemet en komparativ ressurs for sammenligning av nye data fra resultatdatabasen. Dataene ble hentet fra en blanding av ressurser med åpen lisens og opphavsrettsbeskyttet materiale. Totalt sett består datasettet av 597 kar bestående av 3640 forskjellige fotografier. Siden disse dataene er merket, brukte de en overvåket læringsmetode. Resultatdatabasen lagrer brukergenerert tekst og bilder, og skaper en digital samling etter å ha klassifisert skår ved hjelp av automatisert bildegjenkjenning. Tilleggsinformasjonen som samles inn av resultatdatabasen er en ressurs for videre opplæring av deres anerkjennelses- og klassifiseringssystem (Anichini et al., 2020, kap. 1.1).

I tillegg til en massiv digitaliseringsinnsats, brukte de også kunstig intelligens for å generere 3D-modeller av 2D-profiltegninger av keramikk. Ideelt sett ønsket de å lage gjenkjenningsprogramvare som kunne utnytte både dekorasjons- og formbaserte egenskaper; etter mye innsats innså de at dette var utenfor deres økonomiske - og tidsbegrensninger. Ved å utvikle separate algoritmer for hver, fant de ut at deres tidligere genererte 3D-modeller kunne brytes digitalt, noe som skapte sårt tiltrengte treningsdata for deres formbaserte gjenkjenningssalgoritme. Applikasjonen ble også opplært til å forstå terminologi på mange forskjellige språk; dette var essensielt da plattformen skulle være anvendelig i stort sett hele verdenen (*Anichini et al., 2020, kap. 2.2-2.3*). De laget også en rekke interessante datavisualiseringer for appen, for eksempel handelsmønstre for spesifikke typologier. Forfatterne konkluderer med noen primære bekymringer, som viktigheten av tverrfaglig samarbeid, opphavsrettsproblemer og begrensede datasett; jeg diskuterer disse temaene videre i kapittel 5.2.

Programvare for bildegjenkjenning kan som tidligere nevnt brukes til å finne ukjente mønstre i relasjonene mellom ulike kulturelle/typologiske grupper. Denne ideen har blitt utforsket i "A deep-learning model for predictive archaeology and archaeological community detection" (*Resler et al., 2021*). Treningsdatasettet deres besto av 12,364 fotografier av 6770 gjenstander funnet i Sør-Levanten over en periode av 1.5 millioner år (fram til fjortende århundre e.Kr.). For å opprettholde et balansert datasett, begrenset forskerne datasettet til de 200 største klassene, som omfattet 9 909 bilder av 5 450 artefakter, dette utgjør 80,1 % av fotografiene og 80,5 % av artefaktene. Modellen oppnådde høye nøyaktighetsnivåer i å forutsi perioden og funnstedet for gjenstander. Studien sammenligner også modellens ytelse med to arkeologer og fant at modellen hadde høyere gjennomsnittlig nøyaktighet (*fig. 3*). De foreslår at informasjon om gjenstanders opprinnelsessteder har stor betydning for effektiv nettverkslæring.



Figur 3 (Resler et al., 2021)

På sitt mest grunnleggende nivå kan denne CNN modellen hjelpe arkeologer med å effektivt fullføre kjedelige og repeterende oppgaver knyttet til artefaktklassifisering. Men ved sine mer avanserte applikasjoner kan modellen brukes til å analysere store mengder data, avdekke tidligere ukjente sammenhenger mellom folkegrupper, og reise nye arkeologiske spørsmål. Den kan potensielt gi betydelig innsikt i historien og den materielle kulturen til eldgamle samfunn, og har potensial til å bli brukt på andre arkeologiske datasett over hele verden (Resler et al., 2021, 7-9).


4.2 - AI-stedsposisjonsprediksjon

AI kan også brukes til å effektivisere prosessen med å finne steder av arkeologisk interesse gjennom satellitt- og flyfotografering og LiDAR (Light Detection and Ranging - en metode hvor det sendes ut laserpulser, også måles tiden det tar før pulsene spretter tilbake etter å ha truffet objekter eller landskap. Dette produserer detaljerte, tredimensjonale kart over miljøet). Noen har også foreslått inkludering av miljøvariabler som grunnvannsnivå, nedbør og avstander til vannkilder eller veier som ofte er lagt over eldgamle veinett (Sharafi et al., 2016) for å øke nøyaktigheten av teknikkene i de neste to avsnittene.

I artikkelen "Semantic Segmentation of Airborne LiDAR Data in Maya Archaeology" av Bundzel et al. (2020) utforsker de hvordan forskjellige CNN-modeller presterer når det gjelder deteksjon av objekter skjult under vegetasjonstakene til Maya-biosfæreservatet i Petén, Guatemala. De brukte forsterket læring til å trene to CNN modeller på LiDAR-

data fra Pacunam LiDAR Initiative (PLI), som kartla totalt 2144 km². For trening og testing brukte de to forskjellige landområder innenfor det kartlagte området. De brukte manuelt merkede data fra det opprinnelige kartleggingsprosjektet. Vinnermodellen (U-Net) var i stand til å identifisere 60–66% av alle objekter korrekt, og 74–81% av mellomstore objekter. Forfatterne konkluderer med at selv om nevralt nettverk kan være et utrolig verktøy for å effektivisere ekspertenes arbeidsflyt, tror de ikke at programmet helt kan erstatte en ekspert (ennå). Studien belyser betydningen av mellomstore strukturer og hauger for identifikasjon fra et praktisk synspunkt. Deres identifikasjon kan hjelpe forskere til å bedre forstå historien og kulturen til området rundt. Når det gjelder denne studien, var suksessraten for å identifisere mellomstore strukturer og hauger 81 %, noe som forfatterne anser som en betydelig prestasjon. Hvis det oppstår algoritmer som slår menneskelige eksperter i riktig identifisering av mindre arkeologiske gjenstander, kan denne teknologien spare store mengder energi og penger (*Bundzel et al., 2020, 19-20*).

Mens teknologien presentert i forrige avsnitt foreslår en utmerket løsning for områder som allerede har detaljerte LIDAR-data tilgjengelig, eller for de som har midler til å lage dem fra bunnen av, er dette neste eksempelet dedikert til kun å bruke satellittbilder med åpen lisens fra Google Earth som treningsdata (*Karamitrou et al., 2022, 6*). Målet deres var å sammenligne en allerede eksisterende modell (SegNet) med deres spesialbygde 8-lags modell (SimpleNet) spesifikt for denne bruken. De brukte overvåket opplæring for å undervise nettverkene basert på et manuelt merket datasett med 2000 høyoppløselige bilder av arkeologiske steder. De brukte en 70/30-delning for trening og testing. Mens modellen oppnådde en relativt høy nøyaktighetsgrad, er det viktig å merke seg at ytelsen varierer mye avhengig av funntype; dette er en begrensning som er overkommelig med tilstrekkelig treningsdata.



Figur 4 (Karamitrou et al., 2022)

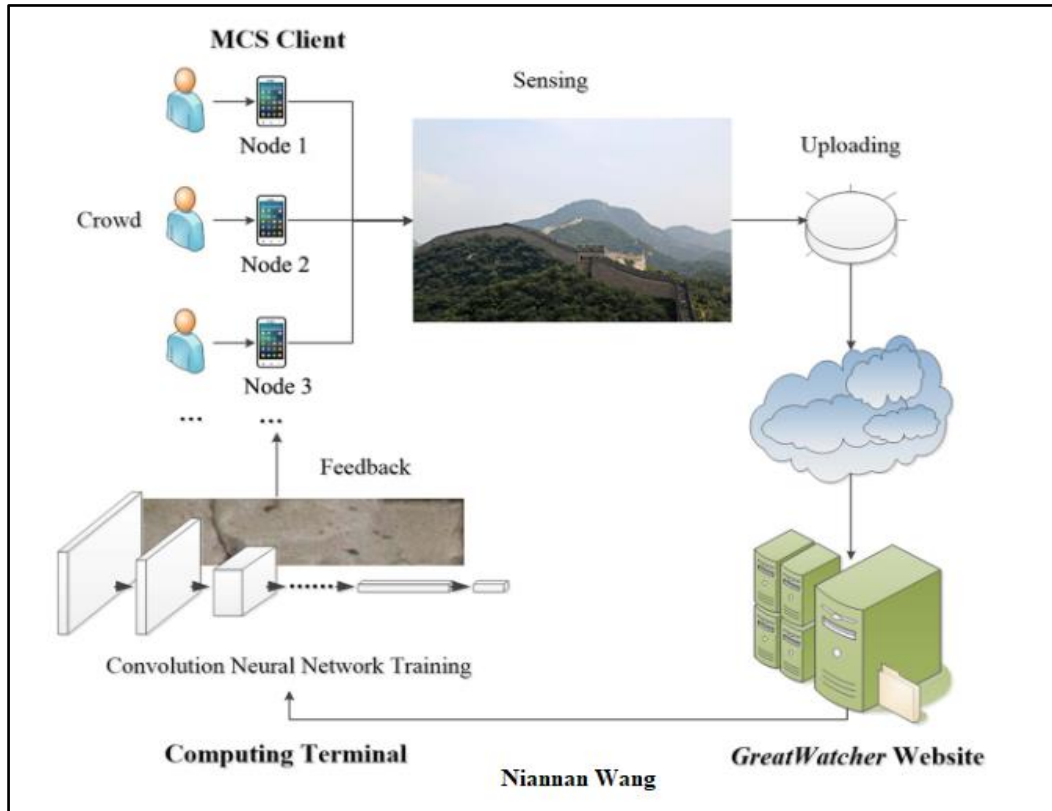
I tillegg betyr den relativt begrensede størrelsen på testdatasettet for noen funksjonstyper at resultatene på disse må tas med en klype salt. Modellen hadde også et betydelig antall falske positive; figur 4 viser hvordan den har riktig identifisert geoglyphen, men også plukker opp mange landskapstrekk som arkeologiske interessepunkter. Selv om teknologien som presenteres i artikkelen har begrensninger,

er det mulig å overvinne disse begrensningene ved å øke mengden merket data som er tilgjengelig for nettverket å lære fra; dette kan gjøres med en delt database. Artikkelen antyder også at automatisk merking ved bruk av georefererte kartdata av arkeologiske steder kan være en mulig fremtidig retning, selv om det kommer med nye utfordringer (Karamitrou et al., 2022, 1-14).

4.3 - Bevaring av kulturminner

Kulturminneforvaltning er, selv om det er et eget felt, nært knyttet til arkeologi. I stedet for å være reaktive, der arkeologer kun er interessert i kulturarv som har forfalt, kan kulturminneforvaltning betraktes som en proaktiv form for arkeologi. Feltet tar sikte på å ta vare på vår kulturarv for fremtidige generasjoner før den kollapser og blir glemt av tidens gang. Derfor føler jeg det er viktig å dekke kort hvordan forskere foreslår bruken av AI for å hjelpe til med bevaring av kulturarv.

For eksempel, i deres "Novel System for Rapid Investigation and Damage Detection in Cultural Heritage Conservation Based on Deep Learning", introduserer Wang et al. (2019) en AI og publikumsbasert løsning for å bevare den kinesiske mur. Tradisjonelt har inspeksjon for vedlikehold blitt utført av eksperter manuelt, så å bruke offentligheten til datainnsamling og AI-algoritmer for å oppdage eventuelle skader vil være enormt nyttig for kulturarvforvaltningsinstitusjonen i Kina. Plattformen fungerer gjennom en Android-basert applikasjon (GreatWatcher) som sender data (spørreskjemaer, bilder og GPS data) til en database, som behandler informasjonen gjennom en CNN (fig. 5).



Figur 5 (Wang et al. 2019)

CNNen ble trent på 610 prøver samlet fra GreatWatcher-plattformen, og testingen konkluderte med at modellen var rundt 78.2% nøyaktig når det gjaldt å klassifisere skadede murstein. Merk at mengden treningsdata er mindre enn ønsket, og nøyaktigheten vil øke ytterligere med et større sett treningsbilder. GreatWatcher-plattformen har vist sitt potensial på den kinesiske mur, men forfatterne påpeker at systemet også kan trenes til bruk på annen kulturarv; primært store strukturer (Wang et al., 2019, 1-14). Man kan også forestille seg implikasjonene av denne teknologien hvis den kombineres med webcrawlere; disse kan automatisk se etter bilder som inneholder geolokaliseringsmetadata for nasjonal kulturarv. Webcrawlere er automatiserte programvareverktøy som navigerer gjennom internettet, besøker nettsider og samler informasjon. De brukes av søkemotorer som Google til å indeksere og organisere den enorme mengden innhold på nettet. Om man kombinerer denne teknologien med et system som GreatWatcher kan nedprioritert kulturarv bli effektivt overvåket uten å gjøre gjenvnlige fysiske inspeksjoner; dette vil lette arbeidsmengden til kulturminneforvaltningen enormt.

4.4 - Epigrafi og språk

NLP (se kap. 2.3.5) har et bredt spekter av anvendelser, som oversettelse, talegjenkjenning og tekstanalyse. De fleste skriftspråk, enten eldgamle eller moderne, deler felles egenskaper og strukturer. Teknikkene for å gjenkjenne moderne skriftspråk kan derfor tilpasses for å analysere og digitalisere eldgamle skriftspråk. Manuell digitalisering av gamle manuskripter er en langsom og kompleks prosess som krever mye ekspertise. Gamle tekster lider også ofte av skade, forfall, tap av informasjon, og de er ofte transportert langt unna det originale funnstedet; dette gjør det vanskelig å kartlegge dialekter og andre forskjeller i språk (Assael et al., 2022, 280). I artikkelen "Restoring and attributing ancient texts using deep neural networks" introduserer de en ML-metode for å øke nøyaktigheten og effektiviteten til den epigrafiske prosessen. De gjorde dette ved å bruke en dyp nevralt nettverksarkitektur som har blitt opplært til å utføre tekstlig restaurering (fig. 5), geografisk attribusjon og kronologisk attribusjon samtidig.



Figur 5 (Wang et al. 2019)

Den ble opplært på eldgamle greske inskripsjoner fra middelhavsregionen mellom 700-tallet f.Kr. og 500-tallet e.Kr. Modellen, som de kalte Ithaca, er tilgjengelig for offentlig bruk og eksperimentering her: <https://ithaca.deepmind.com/>. Ithaca alene når en nøyaktighet på ca. 62%. Som et verktøy for epigrafer vil programmet øke nøyaktigheten og hastigheten til arbeidsflyten deres (Assael et al., 2022, 282-283).

Programvare for bildegjenkjenning (som diskutert i 4.1) har også et bemerkelsesverdig potensial når det gjelder å finne etymologiske sammenhenger mellom språk. En casestudie om dette emnet fant at Indus Valley-skriftet har flere likheter med det fønikiske alfabetet enn med Brahmi-skriftet. Ved å bruke CNN-programvare for bildegjenkjenning trente de en modell på alle kjente symboler fra det fønikiske alfabetet, Indus Valley-skriftet og Brahmi-skriftet. Totalt brukte de bare 3552 bilder, noe som viser hvor effektiv metoden deres er når treningsdata er begrenset; dette gjelder ofte på eldgamle manuskript. Forfatterne påpeker at forskere tidligere har brukt ML teknikker for å analysere bilder og tekst, men bruken av nevralt nettverk for å sammenligne språkfamilier har ikke blitt forsket på mye (*Daggumati & Revesz, 2018*). Å bruke datasyn for å analysere det etymologiske forholdet mellom eldgamle språk kan også fremme vår forståelse av handelsnettverk og bevegelse av mennesker og kultur.

4.5 - aDNA analyse

aDNA er et genetisk materiale av organismer (som planter, dyr eller mennesker) som levde i fortiden. I arkeologi ekstraheres aDNA vanligvis fra bein og tenner, men godt bevart bløtvev er også egnede kandidater for ekstraksjon. Prøvene er ofte forurenset med moderne mikrobiell DNA fra ulike miljøårsaker eller vitenskapere (*Brown & Brown, 1992, 12-13*), og det er her AI-algoritmer kan forenkle og forbedre aDNA-analyse betydelig. Noen eksisterende metoder for å håndtere forurensning, som å filtrere ut lesninger som kartlegger til det menneskelige referansegnetomet eller subtrahere lesninger som samsvarer med kjente forurensninger, kan være for konservative og kan føre til tap av ekte aDNA-lesing (*Kawash et al., 2018, 1-2*). Kawash et al. utviklet en algoritme kalt ARIADNA for å analysere aDNA, filtrere ut sannsynlige forurensninger og finne forbindelser som sannsynligvis ville bli oversett ved bruk av tradisjonelle metoder som Genome Analysis Toolkit (GATK) og Analysis of Next Generation Sequencing Data (ANGSD). Algoritmen ble utviklet ved å bruke en overvåket læringsmetode for å trene et dypt nevralt nettverk på ullen mammut og neandertaler referansegnetomer fra en online database sammenlignet med moderne menneskelig- og elefant DNA. I artikkelen konkluderer de med at ARIADNA utkonkurrerer begge eksisterende filtreringsmetodene den ble testet mot når det gjelder nøyaktighet og sensitivitet for å identifisere genetiske varianter i gamle DNA-prøver. De demonstrerte også skalerbarheten og effektiviteten til ARIADNA, og viste at den kunne behandle store mengder data på kort tid (*Kawash et al., 2018, 2-8*).

4.6 - Kampen mot ulovlig plyndring og handel med kulturarv

Ulovlig plyndring og handel med kulturarv ble først seriøst anerkjent i 1954, og til tross for reguleringsforsøk gjennom lovgivning og internasjonal innsats, fortsetter kulturell eiendomsforbrytelse å skade arv over hele verden (*Abate et al., 2022, 729-730*). Jeg vil dekke to forskjellige måter AI kan brukes til å bekjempe denne ulovlige industrien. For det første kan vi bruke AI- og LIDAR-kartlegging for å identifisere uutgravede steder, og overvåke dem jevnlig (*Danese et al., 2022, 1*). Det andre caset handler om å skanne forum og kommunikasjonsnettverk med en bilde- og tekstbasert AI-tilnærming. Den vil rapportere mistenkelige aktiviteter til kompetente myndigheter som raskt vil kunne reagere og bekjempe dem (*Abate et al., 2022, 729*).

I artikkelen "Pattern Recognition Approach and LiDAR for the Analysis and Mapping of Archaeological Looting: Application to an Etruscan Site" dekker Danese et al. hvordan de analyserer LiDAR-data for å identifisere forstyrrelser i bakkeoverflaten, for eksempel tilstedeværelsen av groper, grøfter eller andre utgravninger som ikke er en del av det opprinnelige arkeologiske området. De gjør dette ved å bruke en overvåket ML-algoritme, som er opplært til å gjenkjenne forstyrrelsesmønstre i LiDAR-dataene som er forbundet med plyndring. Algoritmen trenes ved å bruke både positive og negative eksempler på plyndrede og ikke-plyndrede steder, og brukes deretter til å klassifisere nye steder basert på tilstedeværelse eller fravær av disse forstyrrelsesmønstrene. Steder som er klassifisert med høy sannsynlighet for plyndring, blir deretter undersøkt videre på bakken for å bekrefte tilstedeværelsen av plyndringsaktivitet (*Danese et al., 2022, 14-15*).

EU prosjektet "SIGNIFICANCE (Stop Illicit heritaGe traffickiNg wIth artiFiCiAl iNtelligenCE)" har som mål å bekjempe den ulovlige kulturminnehandelen ved å utvikle en plattform som vil skanne fora og kommunikasjonsnettverk ved hjelp av bilde- og tekstbaserte AI-tilnærminger; dette vil forbedre identifiseringen av gjenstander (ekte eller forfalskninger) som selges og potensielt koble dem sammen for å identifisere kriminelle nettverk. De bruker et CNN som ble trent på et mangfoldig sett med artefakttypologier som gamle mynter, keramikk, ikoner, manuskripter og freskomalerier. Opplæringsdatasettet ble laget ved hjelp av en tredelt tilnærming basert på tradisjonell virkelighetsbasert bildedatainnsamling, manuell datainnsamling fra nettet og nettskrapingsteknikker. Plattformen vil være en nettapplikasjon som viser metadatainformasjon om arveobjekter som handles ulovlig på internett. Den har et brukervennlig grensesnitt med søkekriterier og en dashbordvisning for den innsamlede informasjonen. Plattformen er delt inn i en front-end og en back-end, med en back-end som fungerer som en mellomserver mellom brukergrensesnittet og databasen. Brukeren kan spesifisere nøkkelord og velge plattformmål før webcrawling og AI-analyse starter, og kan varsle myndighetene om ulovlige aktiviteter. Plattformen viser også metadata om identifiserte netttransaksjoner og det relaterte objektet, inkludert informasjon om selger og kjøper. Den opprinnelig trente modellen er rett og slett et proof-of-concept. Andre selskaper eller byråer kan trene applikasjonen til deres spesifikke krav (*Abate et al., 2022, 729-736*).

4.7 - Simulering av historiske og forhistoriske samfunn & formidling

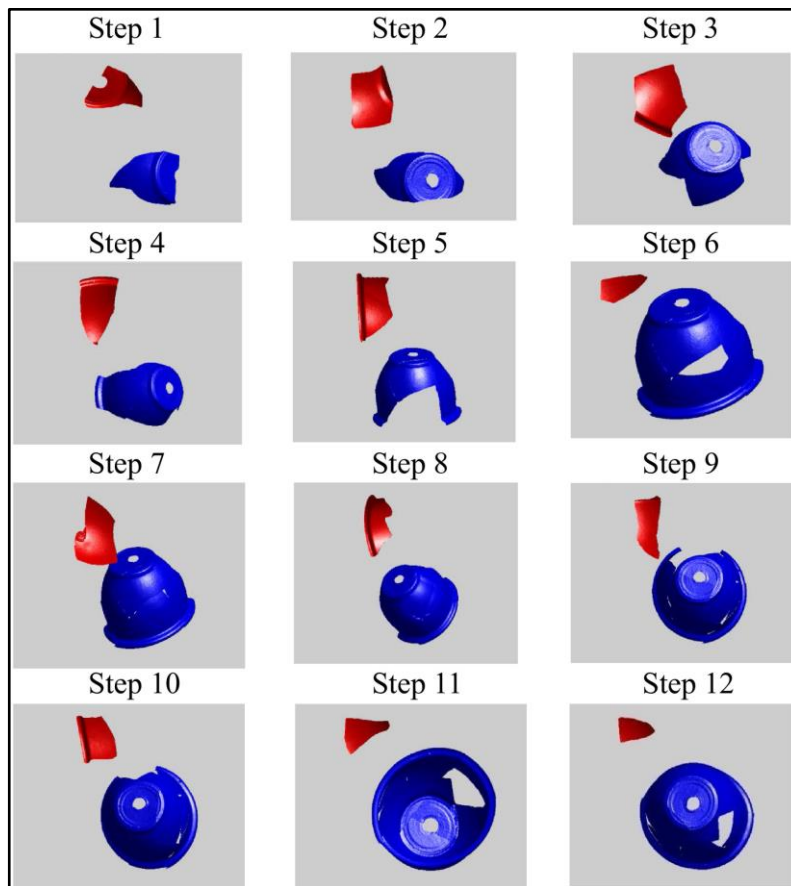
Simuleringen av eldgamle samfunn er et dypt interessant emne som er dekket i dybden av *Juan A. Barceló et al.* i deres bok "Simulating Prehistoric and Ancient Worlds". De understreker at mens virtuelle modeller ikke nødvendigvis kan gi en nøyaktig representasjon av hva som skjedde i fortiden, kan de være nyttige for å generere forklarende argumenter som kan tilpasses virkeligheten (*s. 1-8*). I boken dekker de emner som en AI-simuleringsbasert modell av Out-of-Africa-hypotesen (*Timm et al., 2016*) og innvirkningen av ressursfordeling på den optimale gruppestørrelsen og mobiliteten til jeger-samlergrupper (*Janssen & Hill, 2016*). Selv om det er utenfor omfanget av denne studien å dekke hvert av tilfellene i boken, har jeg valgt å inkludere de to første tilfellene for å formidle løftet om denne teknologien. I tillegg har jeg

inkludert en sak om bruk av simulerte miljøer som et formidlingsverktøy for å gjøre museer mer tilgjengelige (Bogdanovych et al., 2010).

Formidlingen av arkeologisk kunnskap har tradisjonelt gått gjennom museenes utstillinger. Mens digitale nyhetskanaler ofte publiserer arkeologiske nyheter, er det ingen tilgjengelig digital erstatning for museumsutstillinger. Å ha løsninger for digitale utstillinger eller interaktive miljøer gjør museer mer tilgjengelige for dem med fysiske eller psykiske funksjonshemminger. I de senere år har teknologier som virtuell virkelighet (virtual reality - VR), LIDAR og AI-kommunikatører gjort disse ideene oppnåelige. Man kan skape et virtuelt miljø fylt med AI aktører som man kan samhandle med. Denne ideen har blitt utforsket i "Authentic Interactive Reenactment of Cultural Heritage with 3D Virtual Worlds and Artificial Intelligence" (Bogdanovych et al., 2010), der de introduserer en teoretisk 3I-teknologi (*immersive, intelligent, og interactive*), som har som mål å skape autentiske interaktive rekreasjoner av kulturarv med virtuelle 3D-verdener og AI. Artikkelen presenterer en formell modell av kultur som definerer hovedkomponentene og prosessene som er involvert i å skape kulturelt troverdige virtuelle agenter. Modellen består av fire lag: ontologi, normer, personlighet og atferd. Ontologi definerer begrepene og relasjonene som er relevante for en gitt kultur. Normer spesifiserer reglene og forventningene som styrer sosiale interaksjoner innenfor en kultur. Personlighet beskriver de individuelle egenskapene og preferansene til hver agent. Atferd bestemmer hvordan agenter handler og reagerer i ulike situasjoner basert på deres ontologi, normer og personlighet. Mens den foreslåtte modellen var teoretisk da artikkelen ble skrevet i 2010, eksisterer teknologien som kreves for dette, og den kan gjøres sann med tilstrekkelig finansiering.

4.8 - 3D-modellering og rekonstruksjon


Jeg diskuterte veldig kort den automatiserte opprettelsen av 3D-modeller i 4.1, men det er andre interessante måter å bruke AI 3D-modellering på i arkeologi, primært rekonstruksjon av usammenhengende keramikk, og ufullstendig keramikk. Jeg ser også for meg at metodene som diskuteres i dette kapitlet er anvendelig innen for eksempel rekonstruksjonen av flintgjenstander for å analysere metodikken brukt i håndverket. For mitt første eksempel brukte de et backpropagation nevralnettverk (BNN), som trenes ved hjelp av overvåket læring; denne typen nettverk fungerer veldig likt MLP eksempelet fra underkapittel 2.3.1. De bruker funksjonsekstraksjon for å oppdage kantene på hvert keramikkskår, og finne et annet skår med samme geometri, som gjør at de kan passe sammen. Etter å ha montert skårene sammen, bruker algoritmen den samme funksjonsekstraksjonsteknikken på det nyrekonstruerte skåret for å finne neste match. Denne sekvensen fortsetter til rekonstruksjonen er fullført (fig. 6).




Figur 6 (Rasheed & Nordin, 2020)

Forfatterne bemerker at mens dette eksperimentet viser potensialet, brukte de keramikkskår med skarpe og identifiserbare kanter; slik er det ofte ikke i den virkelige verden, og at framtidig forskning bør fokusere på mer tvetydige skår (Rasheed & Nordin, 2020).

Mens det forrige avsnittet beskriver en ideell situasjon med nesten hvert eneste skår av hele konstruksjonen tilgjengelig for deres algoritme, er det ofte deler som mangler. I dette tilfellet har forskere brukt GAN-er (kap. 2.3.3) for å rekonstruere keramikk med (i noen tilfeller) over halvparten av materialet som mangler (Herzoza & Sipiran, 2017, 1).



Figur 7 (Hermoza & Sipiran, 2017)



Figur 8 (Hermoza & Sipiran, 2017)

I denne studien bruker de et program for å vokselisere 6050 3D-modeller av møbler og keramikk, noe som essensielt reduserer oppløsningen til modellene. Dette datasettet er delt inn i 4923 objekter for trening og 1127 objekter for testing. Mens datasettet deres hovedsakelig består av moderne møbler, fant de at modellen deres (ORGAN) var i stand til effektivt å rekonstruere det meste av keramikk (*fig. 7*). De bemerker også at tradisjonelle metoder er avhengige av antagelsen om symmetri, mens ORGAN var i stand til å forutsi, med en viss nøyaktighet, asymmetriske objekter som var ganske ulikt treningsdataene (*fig. 8*) (*Hermoza & Sipiran, 2017*).

5 Diskusjon

Basert på casestudiene i denne gjennomgangen vil diskusjonen deles inn i tre hoveddeler: fordeler, utfordringer og begrensninger, og etiske hensyn. Ettersom arkeologer og AI-forskere jobber sammen for å integrere AI, er det avgjørende å vurdere disse aspektene nøye. Videre er det nødvendig for rettssystemet å tilpasse seg de nye utfordringene og mulighetene som kommer med dette paradigmet. Det innebærer å ta opp spørsmål knyttet til datasikkerhet, personvern og immaterielle rettigheter, samtidig som det sikres at lokalsamfunn og interessenter deltar i beslutningsprosessen. Ved å ta hensyn til disse kompleksitetene kan vi gjøre bedre bruk av AI i arkeologi og bidra til ansvarlig videreutvikling av feltet. Derfor vil jeg i dette kapitlet basere meg på casene i kapittel 4 for å diskutere disse temaene i dybden. Mange av utsagnene i dette kapitlet er basert på min personlige og faglige forskning på AI i forbindelse med denne teksten, og er stort sett mine egne konklusjoner.

5.1 Fordeler

Det er mange positive aspekter ved den utbredte bruken av AI; ved å bruke modellene omtalt i kapittel 4 som et nytt verktøy, ved siden av våre bøtter og spader, kan vi effektivisere, og i noen tilfeller automatisere, de mest tidkrevende og monotone oppgavene i arbeidet, som for eksempel datainntasting og analyse. Fordi så mange moderne AI-modeller er datadrevne, er det viktig å ikke undervurdere rollen til automatisert dataregistrering i fremtiden; dette inkluderer også digitalisering av fysiske arkiver. Fjernanalyse og automatisert identifisering av potensielle utgravingsområder vil også redusere betydningen av fysiske og tidsmessige begrensninger.

Disse verktøyene kan også i noen tilfeller hjelpe oss med å oppnå mer nøyaktige resultater; et eksempel er figur 3 i underkapittel 4.1. Den betydelige forskjellen i nøyaktighet mellom modellen og menneskelige eksperter viser fordelene med å kunne behandle store mengder data raskt. AI sin evne til å behandle store datamengder lar det også avdekke nye mønstre og sammenhenger i store datasett, slik som Riksantikvarens sin [Askeladden-database](#). Dette har potensialet til å gi oss ny innsikt og kunnskap om menneskelig bosetting, migrasjon og arealbruk basert på romlige og tidsmessige data. AI kan analysere de materielle, stilistiske og teknologiske aspektene ved gjenstander for å avdekke forbindelser mellom kulturelle grupper, og identifisere ukjente handelsmønstre (*Anichini et al., 2020, kap. 6*). I tillegg vil det tverrfaglige samarbeidet mellom informatikere og arkeologer uten tvil ha en positiv innvirkning på arkeologien som helhet, da det vil gi nye synspunkter om arkeologisk metodikk og teori fra informatikere.

AI kan også anvendes som personlig lærer eller veileder; det kan revolusjonere måten vi underviser nye arkeologer på. Khan Academy, som er en ideell organisasjon som fokuserer på å lage verktøy for læring, integrerer GPT-4-tjenesten på deres nettside som en personlig veileder ([OpenAI, 2023](#)). Det er mange fordeler med en AI-veileder; den er personlig tilpasset læringsstilen til et individ, den har ubegrenset tålmodighet og umiddelbar tilgang til enorme mengder data som den kan hente svar på et gitt spørsmål fra.

5.2 utfordringer og begrensninger

Det er også en rekke utfordringer med disse nye tilnærmingene. For det første er det viktig å erkjenne at en AI-modell bare er like god som treningsdataene (*Russell & Norvig, 2020, kap. 1.5*). For hver oppgave er det viktig at man bruker et bredt og representativt datasett, og dataene bør være nøyaktig og riktig merket. Gjennom analysen av casestudiene i denne teksten, er manglende eller ufullstendige sett med treningsdata et tilbakevendende problem.

Et annet potensielt problem med treningsdata kan være skjevhet; hvis de trenes med partiske data, kan dette føre til at modellen produserer unøyaktig eller villedende informasjon. Dette er en grunn til at vi ikke bør stole for mye på AI-verktøy, og at alle vurderinger gjort av AI-modeller må valideres før de publiseres. Overdreven avhengighet av AI-verktøy kan også føre til tap av tradisjonell ekspertise som systematisk dokumentasjon, tolkningsferdigheter, typologisering og samarbeid og kommunikasjon, da disse overtas av AI og ikke lenger gjøres av mennesker; dette gjelder spesielt med tanke på chat-modeller som OpenAI sin GPT-serie; diskurs som ellers ville blitt gjort med kollegaer kan gjøres med en chatbot.

Store og komplekse dype nevralt nettverk kan også ha problemer med tolkbarhet og forklarbarhet når det gjelder å forstå et gitt resultat; dette kalles black box-problemet. For eksempel, hvis et keramikkjenkjenningsprogram har tilskrevet romerske amforer til Rhodian-typologien, hvordan vet du hvilke skritt systemet tok for å komme til den konklusjonen? Å forstå hvorfor en modell når en bestemt konklusjon er en viktig del av å kunne stole på resultatene modellen din produserer (*Russell & Norvig, 2020, kap. 19.9.4*). Et annet problem med store modeller er deres beregningskrav; fra 2012 til 2018 var det en 300 000 ganger økning i beregningsbehovet til toppmodellene (*Russell & Norvig, 2020, kap. 1.2.6*). Dette kan sette AI bak en barriere av ressursbegrensninger som finansiering, teknisk ekspertise og tilgang til nødvendig maskinvare og programvare. Forskere jobber imidlertid også mot store AI-modeller som er mindre beregningsmessig krevende ([Meta AI, 2023](#)).

5.3 Etske hensyn

Ved siden av mulighetene og utfordringene, må også en rekke etske hensyn tas opp i diskursen. Spørsmål om datasikkerhet, eierskap, ansvar, balansen mellom vårt opptak av ny teknologi og bevaring av arkeologisk praksis og faglig integritet må tas opp.

Som nevnt i kapittel 4 og forrige underkapittel krever opplæring og vedlikehold av modeller, spesielt større modeller, store mengder data. Slik data kan være sensitiv informasjon angående et funnsted, eller personlig informasjon om for eksempel en levende slektning til en interesseperson fra fortiden. Det må sikres at disse dataene kun gjøres tilgjengelige for dem de gjelder, og håndteres med tilstrekkelig sikkerhet og forsiktighet. Lagring av disse dataene bør derfor gjøres på sikre plattformer, og overføring til andre forskere og institusjoner bør håndteres gjennom krypterte kanaler. I tillegg må det vises vilje til å samarbeide med lokalsamfunn og urfolk når det gjelder respektfull håndtering og bruk av dataene deres. For eksempel kan dette være et problem hvis man utfører arkeologisk forskning i Amish-samfunn, som i stor grad er

motstandere av nyere teknologi. Det er viktig å være gjennomsiktede og åpne om datainnsamling og bruk for å unngå å krenke enkeltpersoner eller grupper.

Spørsmål om forfatterskap og opphavsrett bør også vurderes i diskursen og politikktutforming. Modellene trent og designet av mennesker, og det er hos de menneskene ansvaret til syvende og sist ligger. Forfattere bør alltid opplyse om AI-modeller har produsert arkeologisk kunnskap brukt i deres forskning; og hvis de har, er det viktig å være gjennomsiktede om hvilke metoder og datasett som ble brukt for å legge til rette for kritisk fagfellevurdering. I tillegg, når du bruker AI som hjelpemiddel til å skrive forskningsartikler eller andre akademiske artikler, er det viktig å validere og faktasjekke AI-skrevet tekst, siden skjevhet eller feilinformasjon fra treningsdata kan lekke gjennom. Det juridiske rammeverket rundt opphavsrett bør også utvides til å inkludere AI-samskriving og bruk av datasett for AI-opplæring. Institusjoner må også sette retningslinjer for bruk av AI-assistert skriving og forskning; Å åpne en kommunikasjonskanal mellom institusjoner for å lage standardiserte retningslinjer vil være et skritt i riktig retning.

For å sikre etisk bruk av AI i arkeologi, er det viktig å etablere retningslinjer og politikk som adresserer immaterielle rettigheter og kommersialisering av arkeologiske data og funn som er helt eller delvis produsert av AI. Vi bør utforme retningslinjer som oppfordrer til ansvarlig bruk av AI-teknologi; disse bør dekke datasikkerhet, personvern, potensielle skjevheter i opplæringsdata og inkludering av berørte samfunn i beslutningsprosesser. Å ha klare og omfattende retningslinjer vil bidra til å sikre at AI brukes på en etisk og bærekraftig måte innen arkeologi.

Kraftige AI-verktøy kan også havne i hendene på parter med dårlige hensikter. Verktøyene som er diskutert i denne studien kan potensielt bli brukt av plyndrere som søker økonomisk gevinst eller parter som vil forsøke å ødelegge kulturarven. Å fremme en kultur med ansvar og årvåkenhet vil hjelpe oss til å være et skritt foran ondsinnede parter. I tillegg blir bruk av kunstig intelligens til å prioritere visse arkeologiske interessesteder og identifisere plyndring og handel med ulovlig arv av avgjørende betydning; slik som teknologier nevnt i kapittel 4.6. Å fremme offentlig bevissthet om viktigheten av å ta vare på kulturarven kan også være betydelig for å motvirke disse problemene.

6 Konkluderende tanker

Denne teksten dekker de fleste mulighetene til AI i arkeologi, men det er en umulighet å dekke alt innen et felt i så hurtig utvikling. Jeg er ikke i tvil om at AI vil anspore til et paradigmeskifte ikke bare for arkeologi, men for de fleste vitenskaper. Med dette sagt, mener jeg at AI er et verktøy for utdannede eksperter, og ikke en fullstendig erstatning for den menneskelige arkeologen. Jeg mener hovedmålet til AI-forskning innen arkeologi bør være å lage komplementære verktøy for å lette de mest monotone delene av arkeologien, som for eksempel storskala artefaktklassifisering, digitalisering, analyse av luft- og satellitt fotografering/fotogrammetri, og "big data" analyser. Mens AI-modeller kan produsere resultater med samme nøyaktighet som arkeologer, mener jeg det er viktig at vi opprettholder en kritisk og rasjonell praksis, og dataene produsert av kunstig intelligens *alltid* bør valideres for nøyaktighet.

Figurliste

1. Viser hvordan en AI edge-detection-algoritme kan brukes til bildegjenkjenningsoppgaver. Bildet til venstre er input for en bildegjenkjenningsmodell. Til høyre er et eksempel på hva en modell som denne markerer som kanter og dermed viktig for gjenkjenning.
2. Arbeidsflyten til ArchAIDE-applikasjonen. Viser et eksempel på manuell kantseleksjon; denne manuelle inputen kan også brukes til trening av en automatisk gjenkjenningsalgoritme.
3. En sammenligning av AI modellen og arkeologiske eksperter når det gjelder gjenkjenning av artefakter
4. Et eksempel på prestasjonen av stedsposisjonsprediksjon; algoritmen identifiserer geoglyfen riktig, men gir også noen falske positive fra landskapet rundt
5. En illustrasjon av en gjenoppbygd steintavle fra Ithaca-programvaren.
6. En trinnvis illustrasjon av hvordan AI-modellen rekonstruerer knust keramikk.
7. Ødelagt keramikk blir vokselisert og reparert av algoritmen.
8. Samme test som figur 7, bare med modeller som er ulikt treningsdataen til algoritmen.

Kilder (1058 sider)

- Abate, D., Paolanti, M., Pierdicca, R., Lampropoulos, A., Toumbas, K., Agapiou, A., Vergis, S., Malinverni, E., Petrides, K., Felicetti, A., & Zingaretti, P. (2022). SIGNIFICANCE. STOP ILLICIT HERITAGE TRAFFICKING WITH ARTIFICIAL INTELLIGENCE. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLIII(B2-2022), 729-736. DOI:10.5194/isprs-archives-XLIII-B2-2022-729-2022
- Anichini, F., Banterle, F., Garrigós, J. B., Callieri, M., Dershowitz, N., Dubbini, N., Diaz, D. L., Evans, T., Gattiglia, G., Green, K., Gualandi, M. L., Hervas, M. A., Itkin, B., Fernandez, M. M., Gascón, E. M., Remmy, M., Richards, J., Scopigno, R., Vila, L., ... Zalocco, M. (2020). Developing the ArchAIDE Application: A digital work. *Internet Archaeology*, (52). <https://doi.org/10.11141/ia.52.7>
- Assael, Y., Sommerschild, T., Shillingford, B., Bordbar, M., Pavlopoulos, J., Chatzipanagiotou, M., Androutsopoulos, I., Prag, J., & de Freitas, N. (2022). Restoring and attributing ancient texts using deep neural networks. *Nature*, 603, 280–283. <https://doi.org/10.1038/s41586-022-04448-z>
- Barceló, J. A., & Del Castillo, F. (Eds.). (2016). *Simulating Prehistoric and Ancient Worlds*. Springer International Publishing. <https://link.springer.com/book/10.1007/978-3-319-31481-5>
- Bogdanovych, A., Rodriguez-Aguilar, J. A., Simoff, S., & Cohen, A. (2010). Authentic Interactive Reenactment of Cultural Heritage with 3D Virtual Worlds and Artificial Intelligence. *Applied Artificial Intelligence*, 24(6), 617–647. <https://doi.org/10.1080/08839514.2010.492172>
- Brown, T. A., & Brown, K. A. (1992). Ancient DNA and the archaeologist. *Antiquity*, 66(250), 10 - 23. <https://doi.org/10.1017/S0003598X0008100X>
- Bundzel, M., Jaščur, M., Kováč, M., Lieskovský, T., Sinčák, P., & Tkáčik, T. (2020). Semantic Segmentation of Airborne LiDAR Data in Maya Archaeology. *Remote Sensing*, 12(22), 3685. <https://doi.org/10.3390/rs12223685>
- Daggumati, S., & Revesz, P. Z. (2018). Data Mining Ancient Script Image Data Using Convolutional Neural Networks. *IDEAS - International Database Engineering & Applications Symposium*, 22, 267–272. <https://doi.org/10.1145/3216122.3216163>
- Danese, M., Gioia, D., Vitale, V., Abate, N., Amodio, A. M., Lasaponara, R., & Masini, N. (2022). Pattern Recognition Approach and LiDAR for the Analysis and Mapping of Archaeological Looting: Application to an Etruscan Site. *Remote Sensing*, 14(7), 1587. <https://doi.org/10.3390/rs14071587>
- Doran, J. (1986). Formal methods and archaeological theory: a perspective. *World Archaeology*, 18(1), 21-37. <https://doi.org/10.1080/00438243.1986.9979987>
- European Parliament. (2020, September 4). *What is artificial intelligence and how is it used?* | News. European Parliament. <https://www.europarl.europa.eu/news/en/headlines/society/20200827STO85804/what-is-artificial-intelligence-and-how-is-it-used>
- Ghati, G. (2020, May 3). *Comparison between BERT, GPT-2 and ELMo* | by Gaurav Ghati. Medium. <https://medium.com/@gauravghati/comparison-between-bert-gpt-2-and-elmo-9ad140cd1cda>
- Goertzel, B. (2007). *Artificial General Intelligence* (C. Pennachin & B. Goertzel, Eds.). Springer. kap. 1 <https://link.springer.com/content/pdf/10.1007/978-3-540-68677-4.pdf#page=15>

- Hermoza, R., & Sipiran, I. (2017). *3D Reconstruction of Incomplete Archaeological Objects Using a Generative Adversarial Network (2)*.
<https://arxiv.org/abs/1711.06363>
- Introducing LLaMA: A foundational, 65-billion-parameter language model. (2023, 02 24). Meta AI. <https://ai.facebook.com/blog/large-language-model-llama-meta-ai/>
- Janssen, M. A., & Hill, K. (2016). An Agent-Based Model of Resource Distribution on Hunter-Gatherer Foraging Strategies: Clumped Habitats Favor Lower Mobility, but Result in Higher Foraging Returns. In *Simulating Prehistoric and Ancient Worlds* (pp. 159-173). Springer. <https://link.springer.com/book/10.1007/978-3-319-31481-5>
- Joshi, A. V. (2020). *Machine Learning and Artificial Intelligence*. Springer International Publishing. <https://link.springer.com/content/pdf/10.1007/978-3-030-26622-6.pdf>
- Karamitrou, A., Sturt, F., Bogiatzis, P., & Beresford-Jones, D. (2022). Towards the use of artificial intelligence deep learning networks for detection of archaeological sites. *Surface Topography: Metrology and Properties*, 10(4). 10.1088/2051-672X/ac9492
- Kawash, J. K., Smith, S. D., Karaiskos, S., & Grigoriev, A. (2018). ARIADNA: machine learning method for ancient DNA variant discovery. *DNA Research*, 25(6), Pages 619–627. <https://doi.org/10.1093/dnares/dsy029>
- Mahesh, B. (2020, Januar 1). Machine Learning Algorithms - A Review. *International Journal of Science and Research*, 9(1). 10.21275/ART20203995
- McCarthy, J., Minsky, M., Rochester, N., & Shannon, C. (1955, august 31). *A PROPOSAL FOR THE DARTMOUTH SUMMER RESEARCH PROJECT ON ARTIFICIAL INTELLIGENCE*. <https://web.archive.org/web/20070826230310/http://www-formal.stanford.edu/jmc/history/dartmouth/dartmouth.html>
- Nayak, P. (2022, February 3). *How AI powers great search results*. The Keyword. <https://blog.google/products/search/how-ai-powers-great-search-results/>
- OpenAI. (2023, March 14). *Khan Academy*. OpenAI. <https://openai.com/customer-stories/khan-academy>
- Rasheed, N. A., & Nordin, J. (2020). Reconstruction algorithm for archaeological fragments using slope features. *ETRI Journal*, 42(3), 420-432. <https://doi.org/10.4218/etrij.2018-0461>
- Resler, A., Yeshurun, R., Natalio, F., & Giryas, R. (2021). A deep-learning model for predictive archaeology and archaeological community detection. *Humanit Soc Sci Commun*, 8(295), 1-10.
- Russell, S., & Norvig, P. (2020). In *Artificial Intelligence: A Modern Approach* (4th ed., kap. 1-3, 5, 7, 19-25, 27, 28). Pearson.
- Sanderson, G., & Pullen, J. (2017, Oktober 4). *But what is a Neural Network?* 3Blue1Brown. <https://www.3blue1brown.com/lessons/neural-networks>
- Sharafi, S., Fouladvand, S., Simpson, I., & Barcelo Alvarez, J. A. (2016). Application of pattern recognition in detection of buried archaeological sites based on analysing environmental variables, Khorramabad Plain, West Iran. *Journal of Archaeological Science: Reports*, 8, 206-215. <https://doi.org/10.1016/j.jasrep.2016.06.024>
- Timm, I. J., Lorig, F., Hölzchen, E., & Hertler, C. (2016). Multi-scale Agent-Based Simulation of Long-Term Dispersal Processes: Towards a Sophisticated Simulation Model of Hominin Dispersal. In *Simulating Prehistoric and Ancient Worlds* (pp. 141-156). Springer. <https://link.springer.com/book/10.1007/978-3-319-31481-5>
- TPU vs GPU: Pros and Cons*. (n.d.). OpenMetal. <https://openmetal.io/docs/product-guides/private-cloud/tpu-vs-gpu-pros-and-cons/>

- Turing, A. M. (1950). COMPUTING MACHINERY AND INTELLIGENCE. *Mind*, 59(236), 433–460. <https://doi.org/10.1093/mind/LIX.236.433>
- Wang, N., Zhao, X., Wang, L., & Zou, Z. (2019). Novel System for Rapid Investigation and Damage Detection in Cultural Heritage Conservation Based on Deep Learning. *Journal of Infrastructure Systems*, 25(3). <https://ascelibrary.org/doi/10.1061/%28ASCE%29IS.1943-555X.0000499>
- Weiss, K., Khoshgoftaar, T. M., & Wang, D. (2016). A survey of transfer learning. *Journal of Big Data*, 3(9). <https://journalofbigdata.springeropen.com/articles/10.1186/s40537-016-0043-6#citeas>

