

Sykepleien

FAGUTVIKLING

Oslo universitetssykehus utviklet maskinlæringsmodell for bedre pasientflyt

Et pilotprosjekt viser at sykehus kan utvikle løsninger basert på kunstig intelligens med egne data og begrensede ressurser. Målet er bedre pasientflyt og mer effektiv drift.

Håvard Vangdal

Akuttsykepleier

Avdeling for akuttmottak, Oslo universitetssykehus, Ullevål

Mariann Klingberg

Prosjektleder

Avdeling for organisasjonsutvikling, Oslo universitetssykehus

Cezary Radoslaw Jaskula

Rådgiver og IT-utvikler

Avdeling for teknologi og e-helse, Oslo universitetssykehus

Administrasjon

Akuttsykepleie

Informasjonsteknologi

Sykepleien 2026;113(107961):e-107961

DOI: [10.4220/Sykepleiens.2026.107961](https://doi.org/10.4220/Sykepleiens.2026.107961)

Hovedbudskap

Maskinlæring kan bidra til bedre pasientflyt og ressursplanlegging i sykehus, men utviklingen må skje i tett samarbeid mellom helsepersonell og teknologer. Erfaringene fra Oslo universitetssykehus viser at det er mulig å utvikle KI-modeller internt ved hjelp av egne data, selv med begrensede ressurser og små team. Samtidig viser prosjektet at KI ikke kan erstatte kliniske vurderinger. Teknologien bør brukes som et støtteverktøy for å gjøre pasientflyten tryggere og mer effektiv.

Kan offentlige sykehus utvikle modeller for kunstig intelligens (KI) med egne data og interne ressurser? Vi samlet et lite team for å teste det. Svaret er ja, men med noen viktige forbehold.

Det er behov for å automatisere arbeidsprosesser som i dag gjøres manuelt ved sykehus. Sykepleiere har inngående kunnskap om pasientflyt og kliniske arbeidsprosesser og kan

identifisere oppgaver som kan effektiviseres. Når KI brukes for administrative oppgaver, handler det ofte om å automatisere enkelte vurderinger som i dag gjøres av erfarne sykepleiere.

Maskinlæring kan støtte pasientflyten

I dette prosjektet så vi på arbeidsflyten knyttet til overflytting av pasienter fra akuttmottak til sengepost. Ved en klinikk ved Oslo universitetssykehus (OUS) har en plasseringsansvarlig sykepleier ansvar for å holde oversikt over belegget og fordele pasientene.

Her brukes informasjon fra elektronisk pasientjournal (EPJ), men også fra fysiske runder og telefonkontakt med sengepostene, som igjen avklarer pasientstatus med behandlerne. Først når dette helhetsbildet er på plass, kan pasientene fordeles ut fra kapasitet, behandlingsbehov og en rettferdig fordeling av arbeidsbelastningen.

«Først når helhetsbildet er på plass, kan pasientene fordeles ut fra kapasitet, behandlingsbehov og en rettferdig fordeling av arbeidsbelastningen.»

Vi ønsket å undersøke om noen av vurderingene i denne prosessen kunne automatiseres. Derfor testet vi om det var mulig å forutsi hvor lenge pasientene ville bli innlagt. Slik informasjon kan blant annet brukes til bedre ressursplanlegging og kortere ventetid (1).

Vi valgte denne variabelen fordi risikoen for feilvurderinger er lav, selv om modellens presisjon ikke er perfekt. Maskinlæringsmodellen gir kun prediksjoner og tar ikke kliniske beslutninger. Det vil alltid være helsepersonell som vurderer om nødvendig pasientbehandling er fullført.

Modellen lærer av tidligere pasientforløp

Når teknologer og helsepersonell jobber sammen, blir det lettere å utvikle modeller som passer inn i klinisk praksis (2). Vår erfaring er at et slikt samarbeid kan gi stor gevinst sammenliknet med ressursene som brukes i utviklingsarbeidet.

Det regnes som viktig å teste ut nye IT-konsepter før de innføres i helsesektoren. Små og smidige team har mange fordeler i slike pilotprosjekter (3). Vi ønsket å gjennomføre prosjektet effektivt, uten å legge for mye beslag på ressurser og innenfor en kort tidsramme på tre måneder.

Kunstig intelligens er i rask utvikling og blir stadig mer utbredt. Maskinlæring er en type KI der modeller lærer mønstre fra historiske data. I vårt prosjekt brukte vi data fra tidligere pasientforløp for å undersøke om modellen kunne forutsi hvor lenge nye pasienter ville være innlagt.

I motsetning til tradisjonelle statistiske modeller, som ofte krever en viss grad av forhåndsdefinerte sammenhenger, kan maskinlæringsmodeller oppdage komplekse og ikke-lineære mønstre i data uten at vi spesifikt angir dem (4).

Utviklere og helsepersonell velger variabler sammen

Vi brukte såkalt veiledet maskinlæring. Det innebærer at modellen trenes på et datasett der «fasiten» allerede er kjent – i vårt tilfelle den faktiske oppholdstiden på sykehuset. Denne delen av datasettet kalles treningsdata.

I neste runde mates modellen med data uten fasiten for å validere at den faktisk kan predikere oppholdstid (4). Målet med vår maskinlæringsmodell er å kunne anslå oppholdstid ved hjelp av variabler som allerede er registrert når pasienten kommer til akuttmottaket.

«Det er flere fallgruver i trening av en maskinlæringsmodell.»

Det er flere fallgruver i trening av en maskinlæringsmodell. En variabel uten signifikans, altså uten innvirkning på pasientens oppholdstid, kan føre til støy i modellen. Et enkelt eksempel er pasientens sokkefarge. For de fleste er det åpenbart at sokkefarge ikke har sammenheng med hvor lenge pasienten blir innlagt, men modellen vurderer variabelen på linje med alle andre variabler.

Modellen har, forenklet sagt, ikke evne til å skille verdien av data om sokkefarge fra diagnosekoder. Derfor er tverrfaglig samarbeid viktig. Når helsepersonell og utviklere samarbeider tett, blir det lettere å identifisere og velge variabler som er relevante for klinisk praksis.

Datakvaliteten påvirker modellens treffsikkerhet

En annen utfordring er dersom en variabel ikke har nok data registrert. Vi forsøkte å inkludere høyde og vekt for å beregne kroppsmasseindeks (BMI), men disse opplysningene var registrert for bare én av tre pasienter. Selv om BMI kan påvirke oppholdstiden (5), var datagrunnlaget for svakt til at variabelen kunne brukes i modellen.

Prediksjon av oppholdstid er komplekst og påvirkes av mange faktorer. Noen er knyttet til pasienten, som symptomtrykk, alvorlighet av sykdom og respons på behandling. Andre handler om forhold ved sykehuset, som belegningsgrad, ukedag og tid på døgnet (1).

Studier viser at helsepersonells vurderinger av forventet oppholdstid varierer betydelig (6, 7). Også i studier der maskinlæring har blitt brukt til å predikere oppholdstid, er det varierende feilmarginer (1, 8).

Personvernet ble ivaretatt i analysen

Vi hentet interne data via Regional data- og analyseplattform (RDAP), som samler journaldata fra sykehusene i Helse Sør-Øst. Plattformen gjør det mulig å analysere journaldata i nærmest sanntid.

Vi tok utgangspunkt i variabler fra forskningslitteratur på feltet (1, 5–8), men måtte redusere dette noe grunnet begrenset datatilgang i RDAP og maskinvarekapasitet tilgjengelig ved OUS (se tabell 1).

Tabell 1. Variabler for prediksjon av oppholdstid

Variabel	Kommentar	Inkludert i modell (ja / nei)
Pasientalder	Gruppert i 10-årsintervall	Ja
Kjønn	Mann / kvinne	Ja
Klokkeslett	Ankomsttidspunkt akuttmottak	Ja
Ukedag		Ja
Oppholdstype	Kategorisert i Dips Arena som innleggelse og øyeblikkelig hjelp	Ja
ICD-10-kode	Enkeltvariabel, gjort numerisk med embeddingsmodell	Ja
ICD-10-kode	Antall koder per pasient	Ja
Oppholdstid	Oppholdstid i akuttmottak og på sykehus	Ja (treningsdata)
Høyde		Nei
Vekt		Nei

Personvernombudet ved OUS godkjente utlevering av aidentifiserte data fra 2023 til og med august 2025. I stedet for nøyaktig alder grupperte vi pasientene i aldersgrupper, som styrker personvernet uten å redusere analysens kvalitet i særlig grad.

Modellen krevde omfattende datatilpasning

I oppsettet av maskinlæringsmodellen gikk rundt halvparten av utviklingstiden med til å bearbeide datasettet slik at det ble håndterbart for tilgjengelig maskinvare. Datasettet ble delt i 80 prosent treningsdata og 20 prosent valideringsdata.

En utfordring var tekniske problemer med kodeverk. I vår elektroniske pasientjournal DIPS Arena brukes ulike kodeverk. Ideelt sett ville vi inkludert alle relevante kodeverk, men på grunn av maskinvarebegrensningene valgte vi å bruke ICD-10-koder. Det tok imidlertid tid å lete frem rene ICD-10-koder fra datasettet, fordi de lå gjemt blant andre kodeverk.

For å kunne bruke diagnosekodene i modellen måtte vi gjøre dem om til et format maskinen kunne analysere. Vi valgte en løsning som både reduserte datamengden og samtidig gjorde

det mulig å bevare sammenhenger mellom beslektede diagnoser.

FAKTA

Slik gjorde vi diagnosekoder lesbare for modellen

ICD-10-koder består av bokstaver og tall og kan derfor ikke brukes direkte i numeriske algoritmer. En vanlig løsning er såkalt *one-hot-koding*, men dette gir svært høy dimensjonalitet og lite informasjon om relasjoner mellom kodene. I maskinlæring beskriver dimensjonalitet hvor mange egenskaper eller variabler som brukes til å representere hvert datapunkt. Jo flere dimensjoner, desto mer komplekst blir modellens arbeidsrom.

Vi valgte derfor å bruke en såkalt *embeddingsmodell*, som representerer hver kode som en vektor i et lavdimensjonalt rom. Denne metoden reduserer kompleksiteten og bevarer semantiske likheter mellom kodene. For eksempel vil koder for ulike typer hjertesykdommer ligge nær hverandre. Dette gir modellen bedre forutsetninger for å oppdage kliniske mønstre og sammenhenger, samtidig som beregningskostnaden reduseres.

Prosjektet testet ulike maskinlæringsverktøy

Etter at datasettet var klargjort, begynte vi å trene modellen som skulle predikere oppholdstid. Her brukte vi Python, et programmeringsspråk som er åpent tilgjengelig (9) og fungerer som en stor verktøykasse for dataarbeid.

Python tilbyr en rekke verktøy for utvikling av maskinlæringsmodeller. I prosjektet testet vi TensorFlow og Scikit-learn.

TensorFlow kan sammenliknes med en kraftig maskin – godt egnet til avanserte oppgaver, men den krever mye energi, altså maskinkraft. Scikit-learn er mer som et mindre håndverktøy – bedre for mindre komplekse jobber. Begge hjelper oss med å lage modeller, men de har ulike styrker og bruksområder.

Prosjektet viste at intern KI-utvikling er mulig

Prosjektet viste at det er mulig å utvikle maskinlæringsmodeller internt ved OUS med egne data. Samtidig var datagrunnlaget for svakt til å gi statistisk sikre prediksjoner. Testprosjektet vårt gir likevel en tydelig pekepinn på hva som kreves for å videreutvikle fremtidige KI-prosjekter.

For å utvikle modellen videre trenger vi kraftigere maskinvare. Store datamengder krever betydelig prosesseringskraft og minne for at modellene skal kunne trenes effektivt.

«Begrenset kapasitet kan føre til lange beregningstider, redusert presisjon og utfordringer med å håndtere flere samtidige forespørsler.»

Begrenset kapasitet kan føre til lange beregningstider, redusert presisjon og utfordringer med å håndtere flere samtidige forespørsler. Økt serverkapasitet vil også gjøre det mulig å ta i bruk mer avanserte metoder, som nevrale nettverk, noe som kan identifisere mer komplekse mønstre i dataene.

Nevrale nettverk er en avansert form for maskinlæring og kan gi dypere innsikt i komplekse datasett når ressursene er tilgjengelige.

Relevante variabler gir bedre modeller

Det er også behov for mer data som faktisk påvirker oppholdstiden – altså variabler med dokumentert prediktiv verdi.

Det er en vanlig oppfatning at flere variabler og større datamengder automatisk gir bedre modeller. Men det gir ingen garanti for høyere presisjon eller bedre statistiske resultater.

Effektive modeller bygger på nøye utvalgte variabler og et datagrunnlag som er relevant for problemstillingen, fremfor blindt å øke kompleksiteten (10).

Modellen kan støtte pasientflyten i sanntid


Hva er neste steg? Vi ser for oss en sanntidsløsning som kan bidra til bedre pasientflyt og mer effektiv ressursplanlegging.

Målet er at modellen skal kunne justere prediksjonene fortløpende etter hvert som ny informasjon kommer til. Løsningen skal kunne vise både nåværende og forventet belegg, samt varsle når den predikerte oppholdstiden overskrides.

Verktøyet er ikke ment for å «kaste ut» pasienter, men som et grunnlag for kritisk refleksjon: Har pasienten fått riktig behandling, eller må noe gjøres for å optimalisere behandlingen?

Det er viktig å understreke at prediksjonene aldri skal erstatte kliniske vurderinger, men bidra til at ressursene prioriteres til pasientene som trenger dem mest. En slik løsning kan ikke bare bidra til bedre ressursstyring, men også til økt kvalitet og trygghet i pasientbehandlingen.

Forfatterne oppgir ingen interessekonflikt.



PASIENTFLYT: Arbeidet med å fordele pasienter fra akuttmottak til sengepost bygger i dag på journalopplysninger, telefonkontakt med sengepostene og løpende vurderinger av kapasiteten.

Illustrasjonsfoto: Magic Lens / Shutterstock / NTB

1. Stone K, Zwiggelaar R, Jones P, Mac Parthaláin N. A systematic review of the prediction of hospital length of stay: towards a unified framework. PLOS Digit Health. 2022;1(4):e0000017. DOI: [10.1371/journal.pdig.0000017](https://doi.org/10.1371/journal.pdig.0000017)
2. Vestre Viken HF. Hils på Vidar Viken, Vestre Viken sin digitale medarbeider [internett]. Drammen: Vestre Viken HF; 24. april 2025 [hentet 5. januar 2026]. Tilgjengelig fra: <https://www.vestreviken.no/om-oss/nyheter/hils-pa-vidar-viken-vestre-viken-sin-digitale-medarbeider>
3. Simbo AI. Building and managing cross-functional small teams for healthcare AI pilot projects to align technical and clinical objectives seamlessly [internett]. Cambridge, MA: Simbo AI; u.å. [hentet 5. januar 2026]. Tilgjengelig fra: <https://www.simbo.ai/blog/building-and-managing-cross-functional-small-teams-for-healthcare-ai-pilot-projects-to-align-technical-and-clinical-objectives-seamlessly-3979675>
4. Giskeødegård GF, Lydersen S. Maskinlæring i medisinsk forskning. Tidsskr Norsk Laegeforen. 2023;143(8). DOI: [10.4045/tidsskr.23.0196](https://doi.org/10.4045/tidsskr.23.0196)
5. Hilton CB, Milinovich A, Felix C, Vakharia N, Crone T, Donovan C, et al. Personalized predictions of patient outcomes during and after hospitalization using artificial intelligence. NPJ Digit Med. 2020;3:3:51. DOI: [10.1038/s41746-020-0249-z](https://doi.org/10.1038/s41746-020-0249-z)

6. Nassar AP, Caruso P. ICU physicians are unable to accurately predict length of stay at admission: a prospective study. *Int J Qual Health Care*. 2016;28(1):99–103. DOI: [10.1093/intqhc/mzv112](https://doi.org/10.1093/intqhc/mzv112)
7. Durstenfeld MS, Saybolt MD, Praestgaard A, Kimmel SE. Physician predictions of length of stay of patients admitted with heart failure. *J Hosp Med*. 2016;11(9):642–5. DOI: [10.1002/jhm.2605](https://doi.org/10.1002/jhm.2605)
8. Lequertier V, Wang T, Fondrevelle J, Augusto V, Polazzi S, Duclos A. Length of stay prediction with standardized hospital data from acute and emergency care using a deep neural network. *Med Care*. 2024;62(4):225–34. DOI: [10.1097/MLR.0000000000001975](https://doi.org/10.1097/MLR.0000000000001975)
9. Open Source Initiative. Growing the impact of Open Source around the world [internet]. Palo Alto, CA: Open Source Initiative; u.å. [hentet 5. januar 2026]. Tilgjengelig fra: <https://opensource.org>
10. Keogh E, Mueen A. Curse of dimensionality. I: Sammut C, Webb GI, red. *Encyclopedia of machine learning and data mining*. Boston, MA: Springer; 2017. s. 314–5. DOI: [10.1007/978-1-4899-7687-1_192](https://doi.org/10.1007/978-1-4899-7687-1_192)