



Udvikling af modeller til forudsigelse af 90 dages risiko for forebyggelige indlæggelser blandt hjemmeplejemodtagere og plejehjemsbeboere i Københavns Kommune

Lyndgaard, Christian Bøge; Straubinge, Simon Grundt ; Westh, Karina Vigelsø ; Thyregod, Camilla; Jensen, Sofie Pødenphant; Ersbøll, Bjarne Kjær

Publication date:
2022

Document Version
Publisher's PDF, also known as Version of record

[Link back to DTU Orbit](#)

Citation (APA):
Lyndgaard, C. B., Straubinge, S. G., Westh, K. V., Thyregod, C., Jensen, S. P., & Ersbøll, B. K. (2022). *Udvikling af modeller til forudsigelse af 90 dages risiko for forebyggelige indlæggelser blandt hjemmeplejemodtagere og plejehjemsbeboere i Københavns Kommune*. Technical University of Denmark.

General rights

Copyright and moral rights for the publications made accessible in the public portal are retained by the authors and/or other copyright owners and it is a condition of accessing publications that users recognise and abide by the legal requirements associated with these rights.

- Users may download and print one copy of any publication from the public portal for the purpose of private study or research.
- You may not further distribute the material or use it for any profit-making activity or commercial gain
- You may freely distribute the URL identifying the publication in the public portal

If you believe that this document breaches copyright please contact us providing details, and we will remove access to the work immediately and investigate your claim.



COPENHAGEN
HEALTHTECH
CLUSTER

Udvikling af modeller til forudsigelse af 90 dages risiko for forebyggelige indlæggelser blandt hjemmeplejemodtagere og plejehjemsbeboere i Københavns Kommune

Christian Bøge Lyndgaard (DTU)

Simon Grundt Straubinger (KK)

Karina Vigelsø Westh (COPCAP)

Camilla Thyregod (DTU)

Sofie Pødenphant Jensen (DTU)

Bjarne Kjær Ersbøll (DTU)

Marts 2021

Udvikling af modeller til forudsigelse af 90 dages risiko for forebyggelige indlæggelser blandt hjemmeplejemodtagere og plejehjemsbeboere i Københavns Kommune

Rapport
2021

Af

Christian Bøge Lyndgaard (DTU)

Simon Grundt Straubinger (KK)

Karina Vigelsø Westh (COPCAP)

Camilla Thyregod (DTU)

Sofie Pødenphant Jensen (DTU)

Bjarne Kjær Ersbøll (DTU)

Copyright: Hel eller delvis gengivelse af denne publikation er tilladt med kildeangivelse
Forsidefoto: [Tekst]
Udgivet af: DTU, Institut for Matematik og Computer Science, Richard Petersens Plads,
Bygning 324, 2800 Kgs. Lyngby
www.compute.dtu.dk

KK – Københavns Kommunes Sundheds- og Omsorgsforvaltningen,
Sjællandsgade 40, 2200 København N,
www.kk.dk/institution/sundheds-og-omsorgsforvaltningen-0

COPCAP, Copenhagen Healthtech Cluster, Nørregade 7B, 1165 København K
www.cphhealthtech.dk

ISSN: [0000-0000] (elektronisk udgave)
ISBN: [000-00-0000-000-0] (elektronisk udgave)

ISSN: [0000-0000] (trykt udgave)
ISBN: [000-00-0000-000-0] (trykt udgave)

Forord

Denne rapport er udarbejdet gennem et samarbejde mellem DTU Compute, Københavns Kommunes sundheds- og omsorgsforvaltning, Region Hovedstaden og Copenhagen Healthtech Cluster i 2020.

Arbejdet er udført som en del af projektet *Tidlig opsporing af forebyggelige indlæggelser ved brug af kunstig intelligens (AI) – Fyrtårnsprojektet: Banebrydende sundhedsteknologier*. Projektet er initieret for at reducere antallet af såkaldte forebyggelige indlæggelser af ældre borgere gennem udvikling af data-drevne beslutningsstøttende værktøjer. Projektet er finansieret af Region Hovedstaden.

Rapportens målgruppe er dels forskere eller virksomheder der arbejder med udvikling af beslutningsværktøjer på sundhedsområdet og dels kommunalt ansatte i Sundheds- og Omsorgsforvaltningens centralforvaltning.

Rapporten, samt de udviklede beslutningsstøttende værktøjer er hovedsageligt blevet til gennem udforskning af sammenhænge mellem forebyggelige indlæggelser og offentlige registerdata, sparring med sundhedsfagligt personale i den primære sundhedspleje samt afprøvning af statistiske- og machine learning algoritmer i perioden 2019 – 2020.

Region Hovedstaden, marts 2021

Special konsulent, ph.d. Christian Bøge Lyndgaard (DTU)
Dataanalytiker, M.Sc. Simon Grundt Straubinger (KK)
Projektleder, M.Sc. Karina Vigelsø Westh (COPCAP)
Team leder, ph.d. Camilla Thyregod (DTU)
Adjunkt, ph.d. Sofie Pødenphant Jensen (DTU)
Professor, ph.d. Bjarne Kjær Ersbøll (DTU)

Indhold

Kort sammendrag	6
Langt sammendrag	7
1. Indledning	10
1.1 Baggrund	10
1.2 Formål med rapport	10
1.3 Problemformulering og undersøgende spørgsmål	11
2. Modeller til forudsigelse af genindlæggelse i litteraturen	12
3. Målgruppe og anvendelse	13
3.1 Hvilke ældre skal have indlæggelsesrisiko forudsagt?	13
3.2 Hvem skal bruge forudsigelsen af indlæggelse?	14
3.3 Hvad er en relevant forudsigelseshorisont?	14
4. Forebyggelige indlæggelser	15
4.1 Baggrund om diagnoser	15
4.2 Fordeling af forebyggelige indlæggelsesdiagnoser	17
4.3 Årstidsvariation i forebyggelige indlæggelser	18
5. Forklarende variable	21
5.1 Demografi og uddannelse	21
5.2 Vurdering af funktionsevnetilstand – Fælles Sprog III (FSIII)	22
5.3 Vurdering af helbredstilstand – Fælles Sprog III (FSIII)	24
5.4 Vurdering af boligindretning – Fælles Sprog III (FSIII)	25
5.5 Genoptræning og forebyggelse seneste seks måneder	26
5.6 Visiteret tid til hjemme- og sygepleje	27
5.7 Midlertidig ophold seneste seks måneder	28
5.8 Observationer	28
5.9 Vejr og pollen	28
5.10 Indlæggelser adviseret til kommunen	29
5.11 Indlæggelseshistorik fra landspatientregisteret	29
6. Modeltræning	32
6.1 Valg og fravalg af statistiske modeller	32
6.2 Test- og træningssæt opdeling	34
6.3 Søgning efter bedste model med hyperparameter gridsøgning og krydsvalidering	34
6.4 Forudsig indlæggelse i testsæt med tunede statistiske modeller	36
6.5 Håndtering af årstidsvariation	36
6.6 Hvad er precision og recall?	37
7. Årsmodel for indlæggelsesforudsigelse	39
7.1 Procedure for modeludvikling	39

7.2	Resultater.....	43
7.3	Test sæt præcision per måned	50
7.4	Variable med betydning for forudsigelse af indlæggelse.....	51
7.5	Konklusion	53
8.	Månedsmodeller for indlæggelsesforudsigelse	55
8.1	Procedure for modeludvikling.....	55
8.2	Resultater.....	57
8.3	Sammenligning mellem årsmodellen og månedsmodellen	60
8.4	Konklusion	61
9.	Konklusion.....	62
10.	Anbefalet fremtidigt arbejde	63
11.	Referencer	65
	Bilag A.....	67

Kort sammendrag

Denne rapport omhandler udvikling af prædiktionsmodeller til forudsigelse af 90 dages risiko for indlæggelse med forebyggelige indlæggelser for hjemmeplejemodtagere og plejehjemsbeboere i Københavns Kommune. Motivationen for at forudsige borgeres 90 dages risiko for indlæggelse er at kunne koncentrere forebyggelsesressourcer på borgere med størst risiko og dermed reducere udgifter til indlæggelse og højne borgernes livskvalitet ved at forebygge sygdom. De forebyggelige indlæggelser som defineret af Sundheds- og Ældreministeriet er: nedre luftvejssygdomme, knoglebrud, blærebetændelse, dehydrering, forstoppelse, ernæringsbetinget anæmi, gastroenteroritis, sociale og plejemæssige forhold.

Der er undersøgt sammenhænge mellem forebyggelige indlæggelser og offentlige registerdata (Danmarks Statistik, landspatientregisteret, kommunale data) gennem datavisualiseringer, sparring med sundhedsfagligt personale i den primære sundhedspleje og ved afprøvning af statistiske- og machine learning algoritmer.

Der er forsøgt udviklet 90 dages prædiktionsmodeller for alle ni forebyggelige indlæggelser for hjemmeplejemodtagere og plejehjemsbeboere. Hovedkonklusionen er at kun modellen til forudsigelse af indlæggelse med nedre luftvejssygdom blandt hjemmeplejemodtagere vurderes at have tilstrækkelig høj forudsigelsesevne til at være praktisk brugbar.

De mest betydningsfulde forklarende variable i modellen for nedre luftvejssygdom havde at gøre med borgerens indlæggelsehistorik. Disse forklarende variable kommer fra landspatientregisteret, som på nuværende tidspunkt ikke er tilgængeligt for Københavns Kommune. Den begrænsning gør at modellen for nuværende, ikke kan implementeres og anvendes som beslutningstøttende værktøj i Københavns Kommune.

Rapporten som helhed demonstrerer hvordan indlæggelsesmodeller kan udvikles fra målgruppedefinition til generering af forklarende variable og modeltræning.

Langt sammendrag

Baggrund og formål: denne rapport omhandler udvikling af prædiktionsmodeller til forudsigelse af 90 dages risiko for forebyggelige indlæggelse for hjemmeplejemodtagere og plejehjemsbeboere i Københavns Kommune. De såkaldte forebyggelige indlæggelsestyper er: nedre luftvejssygdomme, knoglebrud, blærebetændelse, dehydrering, forstoppelse, ernæringsbetinget anæmi, gastroenteritis, sociale og plejemæssige forhold. Formålet har endvidere været at undersøge, hvilke borgerdata der viser sammenhæng med fremtidig forebyggelige indlæggelser samt komme med forslag til yderligere indsamling af data i forhold til at forbedre modellernes præcision.

Målgruppe: borgergruppen er afgrænset til borgere i Københavns Kommune der er 65 år eller over og som modtager enten hjemmepleje eller er i permanent plejebolig (plejehjem). Der findes i langt højere grad kommunalt sundhedsdata på disse borgergrupper sammenlignet med borgere på 65 år eller over, der ikke modtager hjemmepleje eller er i permanent plejebolig. Endvidere er andelen af borgere med en forebyggelig indlæggelse 6-7 gange højere blandt hjemmeplejemodtagere og borgere i permanent plejebolig, end borgere der ikke modtager hjemmepleje eller er i permanent plejebolig. Derfor er disse målgrupper valgt. Hjemmeplejemodtagere og borgere i permanent plejebolig er undersøgt og modelleret særskilt dels pga. forskel i tilgængeligt data, og dels pga. at sammenhænge mellem forklarende variable og fremtidig indlæggelse er antaget forskellig.

Outcome: om en borger bliver indlagt med en forebyggelig indlæggelse inden for 90 dage fra forudsigelsestidspunktet. Der er brugt separate outcomes for hver type af forebyggelig indlæggelse f.eks. nedre luftvejssygdom, dehydrering, etc. Prædiktions af indlæggelse med en specifik diagnosetype er vurderet mere brugbar end den bredere definition "en hvilken som helst forebyggelig indlæggelse", idet evt. forebyggende intervention er vurderet afhængig af indlæggelsestypen.

Forklarende variable: der er undersøgt sammenhænge mellem forebyggelige indlæggelser og offentlige registerdata (Danmarks Statistik, landspatientregisteret, kommunale data) gennem datavisualiseringer, sparring med sundhedsfagligt personale i den primære sundhedspleje og ved afprøvning af statistiske- og machine learning algoritmer. Ud fra de offentlige registerdata er der genereret over 700 forklarende variable om borgerne kategoriseret i 11 grupper (demografi og uddannelse, fælles sprog III funktionsevnevurdering, -helbredsvurdering, - boligvurdering, genoptræningshistorik, hjemme- og sygepleje visiteret tid, midlertidige ophold, observationer, vejr og pollental, indlæggelser adviseret til kommunen og indlæggelseshistorik fra landspatientregisteret).

Metode: valg af modelleringstilgang (binær klassifikation) og afprøvede statistiske metoder (logistisk regression med elastisk net, random forest og extreme gradient boosting) er begrundet og procedure for modeludvikling (trænings- og testsæt split, hyperparameter tuning med krydsvalidering, nested krydsvalidering) er beskrevet. Modellers performance er evalueret med *area under the precision-recall curve* (AUCPR), fremfor *area under the receiver operating characteristics curve* (AUCROC ofte blot AUC). AUCPR er valgt idet forholdet mellem ikke indlagte og indlagte er stærkt ubalanceret (29 – 1000 gange flere ikke-indlagt end indlagte).

Modellernes præcision ved 20% recall er givet. For at tydeliggøre modellernes forudsigelsessevne er der ud fra historisk data udregnet

- hvor mange borgere modellerne forudsiger indlagt samt
- hvor mange af disse der rent faktisk blev indlagt

per hhv. 10.000 hjemmeplejemodtagere og 3000 plejehjemsbeboere. For hver indlæggelsesdiagnose er der afprøvet en tilgang med én model udviklet ud fra et års data (årsmodel) og en stratificeret tilgang med 12 månedsmodeller én for hver måned i året (månedsmodeller). Der tages forbehold i resultaterne for at der ikke er foretaget en temporal validering. Dvs. at der ikke været data til at teste modeller andre år end det år, der har været brugt til at udvikle modellerne på. Det kan betyde, at de rapporterede modellers præcision kan være for optimistiske på fremtidige data. Der er udviklet modeller med alt tilgængeligt data samt med det data der på nuværende tidspunkt er tilgængeligt for Københavns Kommune i realtid.

Resultater: Der er udviklet 90 dages forudsigelsesmodeller for alle ni forebyggelige indlæggelsesdiagnoser for hjemmeplejemodtagere og plejehjemsbeboere. Hovedkonklusionen er dog at kun modellen til forudsigelse af indlæggelse med nedre luftvejssygdom blandt hjemmeplejemodtagere vurderes at have tilstrækkelig høj forudsigelsessevne til at være praktisk brugbar. En del af forklaring på hvorfor kun prædiktation af indlæggelse med nedre luftvejssygdom var mulig er at de resterende forebyggelige indlæggelsestyper viste for få indlæggelser indenfor 90 dage til at der kunne udvikles modeller på disse.

Model performance dvs. evnen til at forudsige kan illustreres således for den udviklede indlæggelsesmodel for nedre luftvejssygdom: ud af 10.000 hjemmeplejemodtagere bliver 260 indlagt med nedre luftvejssygdom indenfor 90 dage (gennemsnit 2018). Modellen kan opspore 130 (50% = recall) af de indlagte, ved at fokusere på de 1300 med højest prædikeret risiko. Her er præcisionen 10%, idet kun 130 ud af 1300 forudsagte indlagte faktisk bliver indlagt. Modellen kan også opspore 52 (20% = recall) af de indlagte ved at fokusere på de 182 med højest prædikeret risiko. Her er præcisionen 28,6%, idet kun 52 ud af 182 forudsagte indlagte faktisk bliver indlagt. 182 hjemmeplejemodtagere (ud af 10.000) antages at være et overkommeligt antal borgere at indsætte ekstra forebyggende tiltag. Valget af recall er i rapporten diskuteret i relation til udgifterne forbundet med ekstra forebyggelse versus udgifterne forbundet med indlæggelse.

De 15 mest betydningsfulde forklarende variable i nedre luftvejssygdomsmodellen havde at gøre med borgerens indlæggeshistorik. Disse forklarende variable kommer fra landspatientregisteret, som på nuværende tidspunkt ikke er tilgængeligt for Københavns Kommune. Den begrænsning gør at modellen for nuværende, ikke kan implementeres og anvendes som forudsigelsesværktøj i Københavns Kommune. En model med kun data tilgængeligt for Københavns Kommune har en præcision på 14,5% givet 20% recall. Dvs. at modellen kan opspore 52 (20% = recall) af de indlagte ved at forudsige 358 til indlæggelse. Her antages udgifter forbundet med ekstra forebyggelse, at overstige udgifterne forbundet med indlæggelse.

Konklusion: rapportens hovedkonklusion er at en statistisk model til opsporing af indlæggelse med nedre luftvejssygdom er mulig med anvendelse af tidligere indlæggelsesdata og kommunale data. Såfremt indlæggelsesdata ikke er tilgængelig bliver modellens usikkerhed større, og dermed er det mere usikkert om den kan bruges som forudsigelsesværktøj.

Rapporten som helhed demonstrere hvordan indlæggelsesmodeller kan udvikles fra målgruppe definition til generering af forklarende variable og modeltræning.

1. Indledning

1.1 Baggrund

Danmark har i 2020 5,8 mio. indbyggere, hvoraf 1,2 mio. (20%) er 65 år eller ældre. Danmarks Statistisk estimerer at den danske befolkning i 2040 vil være steget til 6,2 mio. indbyggere med 1,5 mio. (25%) på 65 år eller ældre (Danmarks Statistik, 2020). Med en stigende andel ældre stiger presset også på sundhedsvæsnet og udgifterne til sundhedspleje herunder hjemmepleje, plejeboliger og hospitalsindlæggelser.

Inden for de sidste årtier er forskellige initiativer søsat med det formål, at forebygge hospitalsindlæggelser af ældre borgere. Sundhedsreformen vedtaget i 2007 gav de danske kommuner ansvar for fremme af borgernes sundhed og forebyggelse af sygdom. Ansvar for forebyggelse blev motiveret ved at kommunerne skulle medfinansiere borgeres brug af det regionalt administrerede sundhedsvæsen f.eks. hospitaler og praktiserende læger. Endvidere skulle kommunerne overvåges for antallet af borgere indlagt med såkaldte *forebyggelige indlæggelsesdiagnoser*. De *forebyggelige indlæggelser* er defineret af sundhedsstyrelsen som akutte hospitalsindlæggelsesdiagnoser med større potentiale for forebyggelse end andre indlæggelser, hvis opsporing og intervention foretages tidligt. De udvalgte forebyggelige indlæggelsesdiagnoser er: nedre luftvejssygdomme, knoglebrud, blærebetændelse, dehydrering, forstoppelse, ernæringsbetinget anæmi, gastroenteritis, tryksår og sociale og plejemæssige forhold. I 2013 viste en undersøgelse, at kommuner med høj intensitet i forebyggende initiativer rettet mod kroniske syge og ældre medicinske patienter havde en lavere udgift til medfinansiering per borger i forhold til kommuner med lav intensitet i forebyggende initiativer rettet mod samme borgergruppe (Kommunernes Landsforening, Finansministeret, Økonomi- og Indenrigsministeriet, Ministeriet for Sundhed og Forebyggelse, 2013). Der har således vist sig et økonomisk potentiale i, at investere i øget forebyggelse for denne borgergruppe.

Sundhedsstyrelsen anbefaler systematisk brug af redskaber til tidlig opsporing af sygdomstegn hos ældre gerne med digital understøttelse som f.eks. triagering og TOBS (Tidlig Opsporing af Begyndende Sygdom). Triagering er en proces, hvor medarbejdere i hjemmeplejen og på plejecentrene benytter hverdagsobservationer til at vurdere behovet for forebyggende indsats hos borgeren, idet borgeren klassificeres grøn, gul, eller rød. TOBS er måling og overvågning af vitale parametre som puls, bevidsthed, temperatur, respiration og systolisk blodtryk (Sundhedsstyrelsen, 2017). Hvor disse metoder er velafprøvet, anvendes dog kun en mindre del af det systematiske opsamlede data den øgede digitalisering har gjort tilgængelig de seneste år.

1.2 Formål med rapport

Denne rapport omhandler udvikling af et data-drevet beslutningsværktøj til forudsigelse af ældre der i nær fremtid er i risiko for at blive indlagt med en indlæggelsestype klassificeret som forebyggelig. Hvor redskaber som triagering og TOBS sammenholder data med sygeplejefaglig viden, vil dette projekt tilføje anvendelsen af statistiske og machine learning modeller til - i historisk data - at undersøge sammenhænge mellem de ældres data og efterfølgende indlæggelse med forebyggelige diagnoser. Således undersøges det i hvor høj grad det er muligt at genkende mønstre i ældredata, der kan anvendes til at forudsige om en ældre borger er i høj

risiko for at blive indlagt inden for en given tidshorisont f.eks. 90 dage. Perspektivet, ved et sådant datadrevet forudsigelsesværktøj, er at det i kombination med andre værktøjer som triagering kan være med til et at udpege hvilke ældre der har behov for ekstra forebyggelse. Det overordnede mål er at reducere antallet af indlæggelser blandt ældre og dermed øge livskvaliteten for borgere og samtidig optimere økonomiske sundhedsmidler.

1.3 Problemformulering og undersøgende spørgsmål

Hovedspørgsmål:

I hvor høj grad det er muligt at anvende statistiske og machine learning modeller til at genkende mønstre i ældredata til at forudsige om en ældre borger er i høj risiko for at blive indlagt med en forebyggelige diagnose inden for en given tidshorisont på f.eks. 90 dage.

Underspørgsmål:

- Kan alle forebyggelige diagnoser forudsiges? Hvilke diagnoser kan forudsiges og hvilke kan ikke?
- Hjemmeplejemodtagere og permanente beboere i plejehjem undersøges særskilt. Kan alle indlæggelser forudsiges i begge grupper?
- Hvad er en passende forudsigelsehorisont? 30, 60 eller 90 dage?
- Hvilke slags data er bedst til at forudsige de ældres fremtidig indlæggelse?
- Kan forudsigelse af indlæggelse laves udelukkende ud fra kommunalt data?
- Kan andet data end det nuværende tilgængelige med fordel anvendes?
- Er der årstidsvariation i antal indlæggelser? Nedre luftvejssygdomme formodes f.eks. at være hyppigere i vinterhalvåret. Hvordan håndteres årstidsvariation i et beslutningsværktøj?
- Hvordan håndteres afhængighed mellem indlæggelsestyper? F.eks. hvis en ældre er indlagt med nedre luftvejssygdomme er risikoen for indlæggelse med knoglebrud lille idet den ældre er beskyttet på hospitalet.
- Hvordan kunne et sådant beslutningsværktøj bruges og passe ind i det sundhedsfaglige personales arbejde?
- Hvad er usikkerheden ved forudsigelse af indlæggelse (antal falske positive og falske negativ) og hvad er acceptabelt for slutbrugerne f.eks. hjemmeplejesygeplejersker?

2. Modeller til forudsigelse af genindlæggelse i litteraturen

Der er i langt højere grad publiceret forskningsartikler om forudsigelse af genindlæggelse frem for indlæggelse. En *genindlæggelse* er en indlæggelse kort tid f.eks. 30 dage efter udskrivelse fra en indlæggelse. En *indlæggelse* inkluderer genindlæggelser, men er også indlæggelser hvor der ikke har været indlæggelser kort tid før. Populationen af individer i genindlæggelsesmodeller har således alle været indlagt indenfor kort tid. Det bevirker at denne population generelt er i et højere risikoniveau end individer der ikke lige har været indlagt.

En oversigtsartikel af Artetxe et al. (2018) identificerede 77 forskningsartikler omhandlende forudsigelse af genindlæggelser. Artiklen sammenholder studierne population, feature selectionsmetode, klassifikationsalgoritme, stikprøvestørrelse og modellernes forudsigelsesperformance. 68% af studierne anvender logistisk regression eller andre regressionsmetoder, 13% anvender overlevelseanalyse, mens 14% anvender machine learning metoder hovedsageligt beslutningstræ og support vector machinces. Artetxe et al. (2018) finder at kun 4 studier anvender teknikker til at håndtere klasseubalance dvs. at der ofte er meget færre personer der indlægges i forhold til personer der ikke indlægges.

Forudsigelsesperformance blandt studierne blev fundet til at en Area Under the ROC curve (AUC) på 0.54 – 0.92. Samlet set konkluderes at machine learning metoders popularitet er stigende og at nylige comparative metode studier viser at machine learning metoder kan forbedre forudsigelsesevne i forhold til traditionelle statistiske metoder.

Artetxe et al. (2018) finder at forudsigelseshorizonten anvendt i studierne spænder fra 48 timer til et år, men hovedparten (58%) af studierne anvender en 30 dages forudsigelseshorizont. Gennemsnittet af genindlæggelsesraten (andel der genindlægges) indenfor 30 dage mellem studierne blev fundet til 16%. Det er en høj andel indlagte set i forhold at kun 2% af hjemmeplejemodtagere i Københavns Kommune er fundet indlagt med forebyggelige indlæggelser indenfor 30 dage (data ikke vist). Blandt årsager til denne store forskel mellem andel indlagte kan være at Artetxe et al. (2018) studierne populationer har været indlagt indenfor kort tid og derfor er i et højere risikoniveau. Endvidere inkluderer studierne typisk et bredere udsnit af diagnose typer end i nærværende rapport hvor det kun er forebyggelige diagnoser.

3. Målgruppe og anvendelse

3.1 Hvilke ældre skal have indlæggelsesrisiko forudsagt?

I gennem rapporten vil et udsnit af borgere (en kohorte) blive brugt som eksempel til udforskning af data. Denne kohorte er defineret som borgere der 1. januar 2018 er:

- Bosiddende i Københavns Kommune
- 65 år eller ældre
- enten på plejehjem eller modtager hjemme- og/eller sygepleje

Tabel 1 viser fordelingen af Københavns Kommunes ældre (65 år eller ældre) på borgergruppe d. 1. januar 2018. Ud af de 62.772 borgere på 65 år eller ældre modtager 50.819 (81%) hverken hjemme- eller sygepleje eller bor på plejehjem. De resterende 11.953 (19%) er enten modtagere af hjemme- og/eller sygepleje (9017, 14%) eller bo på plejehjem (2936, 5%).

Tabel 1. Fordeling af Københavns Kommunes borgere på 65 år eller ældre på borgergruppe d. 1. januar 2018.

Borgergruppe	Antal	Andel (%)
Hjemme- og sygepleje	9017	14
Plejehjem	2936	5
Hverken i hjemmepleje eller plejehjem	50819	81
Total	62772	100

Det er ældre i hjemmepleje og plejehjem, der er målgruppen for indlæggelsesforudsigelse (beslutningsværktøjet) i denne rapport. Dette valg er truffet ud fra, at der findes meget mere omsorgs- og sundhedsdata på denne gruppe end på ældregruppen, der ikke modtager hjemmepleje eller er på plejehjem. Den større mængde omsorgs- og sundhedsdata skyldes blandt andet at der ved visitationsforløbet til hjemmepleje eller plejehjem foretages en lang række funktions- og helbreds-vurdering gennem den dokumentationspraksis der kaldes *Fælles sprog 3* (se mere om dette senere i sektion 5 Forklarende variable).

En anden årsag til valget af målgruppen hjemmeplejemodtagere og plejhjemsbeboere, skyldes at andelen af forebyggelige indlæggelser er langt højere i denne gruppe end gruppen der hverken er i hjemmepleje eller plejehjem (Tabel 2). Det ses ud fra Tabel 2 at andelen af indlagte med en forebyggelig diagnose indenfor 90 dage er langt højere for hjemmeplejemodtagere (5,7%) og plejhjemsbeboere (6,7%) end gruppen der hverken er i hjemmepleje eller på plejehjem (1,0%). Selvom hjemmeplejemodtagere og plejhjemsbeboerne kun udgør 19% af de ældre står gruppen for hovedparten af de forebyggelige indlæggelser.

Tabel 2. Fordeling af Københavns Kommunes borgere på 65 år eller over mht. borgergruppe og indlæggelse vs. ikke indlæggelse med forebyggelig diagnose indenfor 30 dage d. 1. januar 2018.

Borgergruppe	Indlæggelse indenfor 90 dage	
	Antal ikke indlagt (%)	Antal indlagt (%)
Hjemme- og sygepleje	8.502 (94,3)	515 (5,7)
Plejehjem	2.740 (93,3)	196 (6,7)
Hverken i hjemmepleje eller plejehjem	50.296 (99,0)	523 (1,0)
Total	61.538 (98,0)	1234 (2,0)

3.2 Hvem skal bruge forudsigelsen af indlæggelse?

Udvikling af en forudsigelsesmodel hænger sammen med

- hvem skal anvende forudsigelsen?
- hvordan skal forudsigelsen bruges?

Den 29. juni 2020 blev disse spørgsmål diskuteret ved et møde med sundhedsfagligt personale fra Sundheds- og Omsorgsforvaltningen i København Kommune. Ved dette møde blev der præsenteret at de forudsigelsesmodeller der kan udvikles, ikke kan forudsige perfekt. Forudsigelsesmodeller vil kun kunne opspore 20-30% af dem der bliver indlagt, hvis ikke antallet af falske positive skal overstige et praktisk anvendeligt antal. Det blev bekræftet at et forudsigelsessværktøj, som kan opspore 20-30% stadig er meget relevant og brugbart og at falske positive er forventet.

Ved mødet blev der i øvrigt diskuteret hvorvidt indlæggelsesforudsigelser kunne anvendes praktisk. Det sundhedsfaglige personale forestillede sig at sådanne forudsigelser kunne blive sammenholdt med sundhedsfaglig viden og eksisterende vurderingsredskaber som triagering og TOBS og således kan være med til at fokusere hvilke borgere, hvor der indsættes et forebyggende tiltag.

Hvor triagering, TOBS og almindelig sundhedsfaglig viden bygger på klinisk faglig viden, forskning og erfaringer, er en indlæggelsesforudsigelse fra en statistisk model baseret på de mønstre der har kendetegnet indlæggelser historisk set.

3.3 Hvad er en relevant forudsigelseshorisont?

En forudsigelseshorisont er hvor lang tid ud i fremtiden man ønsker at forudsige om en borger vil blive indlagt. I dette projekt har følgende forudsigelseshorisonter været diskuteret: 30, 60, 90 dage.

En kort horisont f.eks. 30 dage giver en relativ lille andel borgere, der bliver indlagte og det kan blive en udfordring når en statistisk model skal finde mønstre i borgernes forklarende variable der forudsiger fremtidig indlæggelse. Omvendt kan en kort horisont betyde at de forklarende variable er mere opdaterede. Fra brugeren af forudsigelsen kan en kort horisont tænkes fordelagtig, idet der muligvis kan forebygges mere præcist. Omvendt kan man forestille sig at nogle forebyggende tiltag enten vil tage tid at implementere og/eller skal implementeres i god tid før en eventuel indlæggelse for at have en virkning. En *lang horisont* f.eks. 90 dage vil give de modsatte effekter som større andel indlæggelser dvs. lettere at udvikle statistisk model, mindre opdaterede forklarende variable.

Det sundhedsfaglige personale ved Københavns Kommune har vurderet at en forudsigelseshorisont på mere end 30 dage bliver for lang tid. Denne vurdering uddybes med at plejepersonalet vil have svært ved at holde fokus på ekstra forebyggelse i mere end 30 dage (Norquist, 2020). På trods af dette, kan det give mening ud fra et modelleringssynspunkt at udvikle en model der forudsiger længere ud i horisonten dels fordi modellen vil have et større datagrundlag i form af flere indlæggelser og derfor vil kunne blive mere præcis i sin forudsigelse dvs. nedbringe antal falsk positive og negative.

4. Forebyggelige indlæggelser

4.1 Baggrund om diagnoser

Definitionen af forebyggelige indlæggelser er akutte hospitalsindlæggelser med større potentiale for forebyggelse end øvrige indlæggelser hvis opsporing og intervention fortages tidligt (Kommunernes Landsforening, Finansministeret, Økonomi- og Indenrigsministeriet, Ministeriet for Sundhed og Forebyggelse, 2013). Forebyggelige indlæggelser er indlæggelser blandt borgere på 65 år eller derover indenfor en af følgende diagnoser:

- Dehydrering
- Nedre luftvejssygdomme
- Blærebetændelse
- Brud
- Forstoppelse
- Tryksår
- Gastroenteritis
- Ernæringsbetinget anæmi
- Sociale og plejemæssige forhold og tryksår.

Nedre luftvejssygdom er den diagnose, der er mest hyppig blandt de forebyggelige indlæggelser både på landsplan og i Københavns Kommune som angivet i Tabel 3. (kilde: Simons KØS/LPR). I Københavns Kommune indlægges omkring 2500 borgere pr. år med diagnosen nedre luftvejssygdomme, mens der på landsplan årligt indlægges mere end 30.000 ældre borgere med diagnosen. Endvidere er diagnoserne brud, blærebetændelse og dehydrering også årsag til mange hospitalsindlæggelser årligt. De øvrige forebyggelige diagnoser er repræsenteret med væsentlig færre tilfælde pr. år.

Tabel 3. Årligt antal indlæggelser af de fire mest hyppigste forebyggelige diagnoser i Københavns Kommune og på landsplan (kilde?).

Forebyggelig indlæggelsesdiagnose	Årligt antal	
	Københavns Kommune	Landsplan
Nedre luftvejssygdomme	2500	30.000
Knoglebrud	1000	16.000
Dehydrering	600	6.000
Blærebetændelse	400	4.500

Det forventes, at antallet af forebyggelige indlæggelser varierer i relation til årstid, da det forventes at der er flere indlæggelser med nedre luftvejssygdomme, særligt lungebetændelse, og brud i de kolde og glatte vintermåneder, mens der pga. varmere temperaturer indlægges flere med dehydrering i sommerhalvåret. Denne årstidsvariation skal der tages højde for når indlæggelser forsøges forudsagt.

Borgere på 65+ år har desuden nedsat immunforsvar og hvis borgere også har en eller flere kroniske lidelser som KOL, astma, hjertesygdom eller diabetes er de særligt i risikozonen for nedre luftvejssygdomme. Nedsat funktionsevne defineres som en reduktion i borgerens evne til

at udføre vanlige aktiviteter og anvendes som risikofaktor for forebyggelige indlæggelser af borgere, især indlæggelser med nedre luftvejssygdomme (kilde?).


Det forventes at adskillige forklarende variable i de tilgængelige kommunale data har betydning for flere af de forebyggelige diagnoser, mens nogle forklarende variable spiller en særlig vigtig rolle i specifikke diagnoser. Nedsat funktionsevne kan f.eks. have betydning for mange af indlæggelserne, mens genoptræningsdata derimod forventes, at have en større betydning for bruddiagnoser sammenholdt med genoptrænings betydning for fx blærebetændelse.

Knoglebrud opstår typisk efter fald og ulykker. Årsagerne til fald er forskellige og kan skyldes hændelige uheld eller borgeres øvrige diagnoser som fx demens, hvor borgerne ikke er klar over hvad deres fysiske formåen er. Brud kan også skyldes fald ud af seng eller kørestol, fastklemning i døre, fald fra træningsredskaber. Forebyggende træning vil styrke dels muskulaturen omkring klogler og led og dels borgernes evne til at reagere og korrigere fald og minimere risikoen for brud. Knoglebrud der medfører inaktivitet kan efterfølgende føre til andre forebyggelige indlæggelser som tryksår og forstoppelse.

Dehydrering, som følge af væskemangel, kan have sammenhæng med en række af de andre forebyggelige indlæggelsesdiagnoser fx forstoppelse og blærebetændelse. Tilstrækkeligt væskeindtag påvirker både dehydrering og blærebetændelsesdiagnosen.

4.2 Fordeling af forebyggelige indlæggelsesdiagnoser

Figur 1 viser andel (%) indlagt med en forebyggelig diagnose indenfor 90 dage blandt borgere i Københavns Kommune der 1. januar 2018 modtog hjemme- og/eller sygepleje eller var på plejehjem. Tallene midt på barerne angiver antal indlagte. F.eks. ses at omkring 4% af hjemmeplejemodtagere (357 ud af 9017, se Tabel 1) blev indlagt med nedre luftvejssygdom indenfor 90 dage. Sammenfattende for begge borgergrupper ses at nedre luftvejssygdom er den hyppigste forebyggelige indlæggelsesdiagnose med 4-5% indlagt indenfor 90 dage. Næst hyppigst er indlæggelse for dehydrering (0,9%) og knoglebrud (0,8%) indenfor 90 dage.



Figur 1. Andel (%) indlagt med forebyggelig diagnose indenfor 90 dage blandt borgere i Københavns Kommune der 1. januar 2018 modtog hjemme- eller sygepleje (venstre plot) eller var på plejehjem (højre plot). Tallene midt på barerne angiver antal indlagte. Manglende barer eller tal angiver < 5 borgere er bag, hvilke er maskeret jvf. Danmarks Statistiks regler om mikrodata.

Fra et forudsigelsessynspunkt er antallet af indlagte meget lavt ud over disse top 3 forebyggelige diagnoser. Hvis antallet af indlagte er meget lavt, kræver det forklarende variable med meget kraftigt "signal" dvs. forklarende variable (eller interaktioner) med entydigt forskellige værdier mellem de borgere der bliver indlagt og de borgere der ikke bliver indlagt.

Endvidere giver meget få indlagte et problem med uafhængig validering af modellernes forudsigelsesevne. Ved validering vil der typisk tilfældigt udvælges en andel af borgere der udelades af modelleringen (såkaldt testsæt) for efterfølgende at teste den endelige models forudsigelsesevne. Med meget få indlagte stiger risikoen for at ikke-repræsentative borgere ender i testsættet (også kaldet testsæt varians) og en models forudsigelsesevne kan således fremstå for optimistisk eller pessimistisk. Dette kan til dels håndteres med såkaldt krydsvalidering og nested krydsvalidering, men generelt bliver den estimerede forudsigelsesevne behæftet med større usikkerhed når antallet af cases (indlagte) er meget lavt.

Mindre end 10 indlagte vurderes i nærværende rapport som meget få. Med den vurdering viser Figur 1 at det med 90 dages horisont kun giver mening at forsøge at udvikle modeller baseret på data fra hjemmeplejemodtagere for de forebyggelige indlæggelser med nedre luftvejssygdom, dehydrering, brud, blærebetændelse, forstoppelse og gastroenteritis og på data fra borgere i plejebolig kun for nedre luftvejssygdom, dehydrering, brud og blærebetændelse.

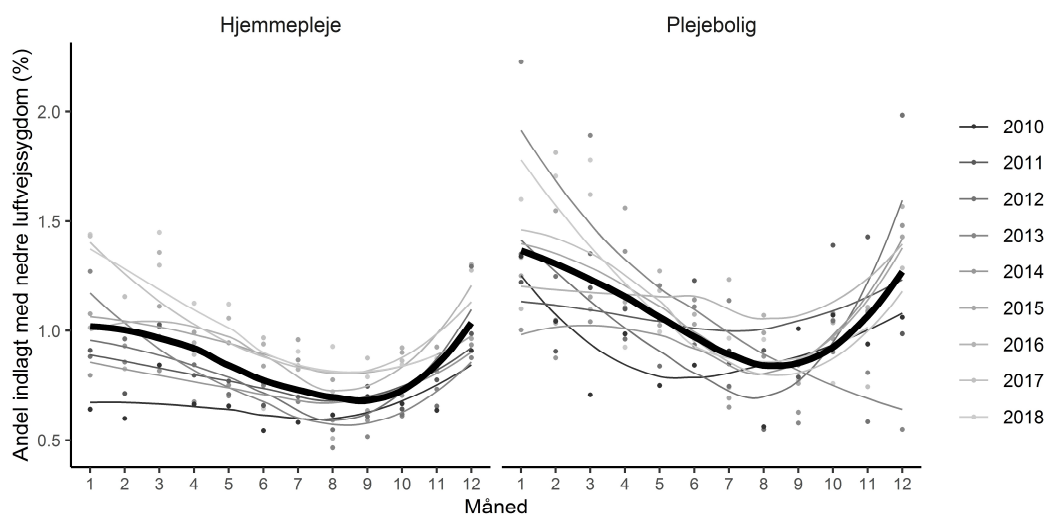
En måde at skabe et datasæt med flere indlagte er ved at sammenlægge data fra borgere fra forskellige perioder f.eks. en måned forskudt som beskrives nærmere i nedenstående afsnit 6.5 (Håndtering af årstidsvariation). En anden måde at øge antallet af indlagte er ved at

sammenlægge alle forebyggelige diagnoser så modellen forsøger at forudsige om en borger bliver indlagt med en hvilken som helst diagnose. Problemet med denne tilgang er at det vil blive sværere for brugeren af forudsigelsen at vide hvilken forebyggelse, der skal foretages idet det ikke vides hvilken slags indlæggelse borgeren er i risiko for. Endelig kan problemet med få indlagte blive forsøgt løst ved at upsamle / vægte indlagte under modelleringen (se afsnit 6.1 Valg og fravalg af statistiske modeller).

4.3 Årstidsvariation i forebyggelige indlæggelser

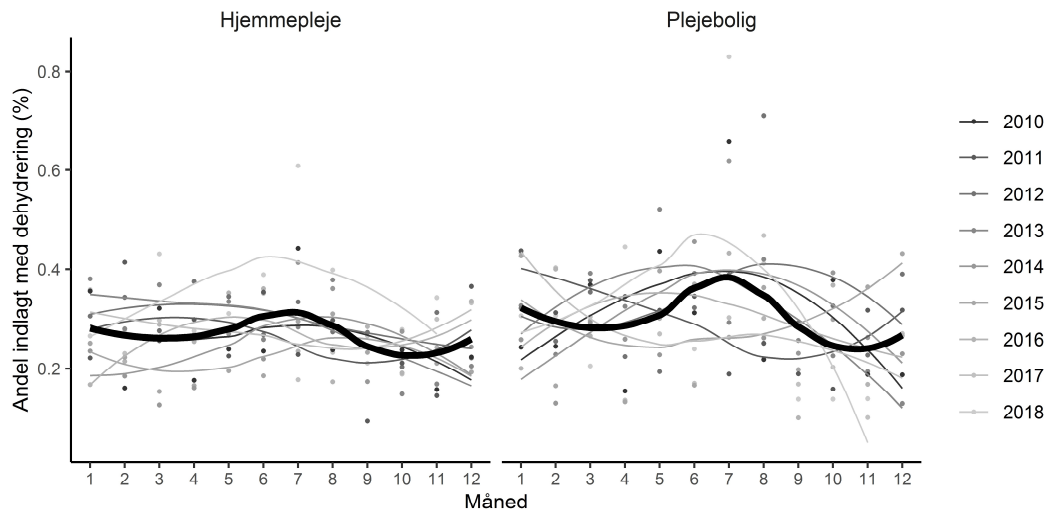
Udvikling af en forudsigelsesmodel indbefatter undersøgelse af om de forebyggelige indlæggelser er årstidsafhængige. Inspektion af plots af indlæggelser vs. kalendermåned for hver forebyggelig diagnose viser at indlæggelse med nedre luftvejssygdom (Figur 2) og dehydrering (Figur 3) er årstidsafhængige. De resterende forebyggelige diagnoser viste ingen markant årstidsvariation, og er derfor ikke vist her.

Figur 2 viser den månedlige andel af indlæggelser med nedre luftvejssygdom versus kalendermåned for hjemmeplejemodtagere og plejehjemsbeboere i perioden januar 2010 – december 2018. Den samlede trendkurve for alle år (sorte tykke kurve) viser samme årstidsudvikling for hjemmeplejemodtagere og plejehjemsbeboere, selvom andelen indlagte er ca. 0,5% point højere for plejeboligbeboere. Det ses at andelen af indlæggelser med nedre luftvejssygdom er lavest i sommermånederne og højest i vintermånederne, dog lidt forskudt med et lavpunkt omkring august.



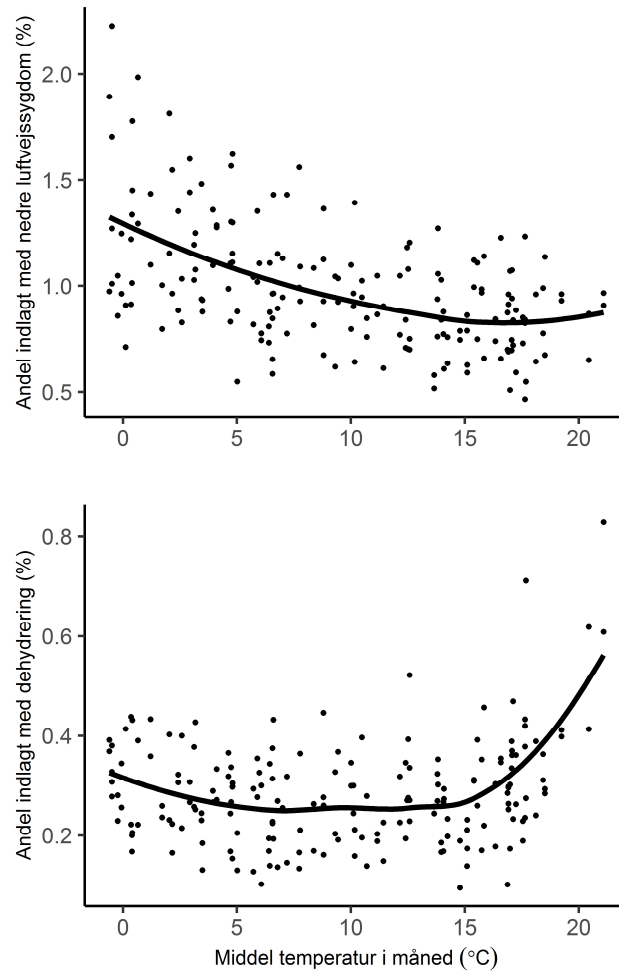
Figur 2. Andel (%) borgere i Københavns Kommune i hjemmepleje (venstre) og plejebolig (højre) der indlægges med nedre luftvejssygdom vs. måned i perioden januar 2010 - december 2018. Tynde linjer viser trendkurve inden for hvert år og tykke linjer viser samlet trendkurve for alle år. Trendkurver er estimeret med loess (locally estimated scatterplot smoothing).

Figur 3 viser den månedlige andel af indlæggelser med dehydrering versus kalendermåned for hjemmeplejemodtagere og plejehjemsbeboere i perioden januar 2010 – december 2018. Den samlede trendkurve for alle år (sorte tykke kurve) viser samme årstidsudvikling for hjemmeplejemodtagere og plejehjemsbeboere. Det ses at andelen af indlæggelser med dehydrering er højest i sommermånederne og nogenlunde konstant resten af året.



Figur 3. Andel (%) borgere i Københavns Kommune i hjemmepleje (venstre) og plejebolig (højre) der indlægges med dehydrering vs. måned perioden januar 2010 - december 2018. Tynde linjer viser trendkurve inden for hvert år og tykke linjer viser samlet trendkurve for alle år. Trendkurver er estimeret med loess (locally estimated scatterplot smoothing).

De tynde trendkurver i Figur 2 og Figur 3 viser årlige trends og det ses at der er stor forskel mellem år særligt for indlæggelse med dehydrering. En medvirkende årsag til forskelle mellem år kunne være temperaturforskelle mellem år. Figur 4 viser andel indlagte med nedre luftvejssygdom (øvre plot) og dehydrering (nedre plot) for månederne i perioden januar 2010 – december 2018 versus middeltemperatur i måneden. Trendkurven for nedre luftvejssygdom viser at månedlig andel indlæggelser er ca. 1,3% ved en middeltemperatur på 0°C faldende til ca. 0,9% ved en middeltemperatur på 15°C, hvorefter andelen er konstant. Trendkurven for dehydrering viser at månedlig andel indlæggelser er ca. 0,3% ved en middeltemperatur på 0-15°C, hvorefter andelen stiger til ca. 0,6% ved en middeltemperatur på 21°C.



Figur 4. Andel (%) borgere i Københavns Kommune i hjemmepleje og plejebolig per måned indlagt med nedre luftvejssygdom (øvre) og dehydrering (nedre) versus. hhv. middeltemperatur i måned perioden januar 2010 – december 2018 Trendkurver er estimeret med loess (locally estimated scatterplot smoothing).

5. Forklarende variable

Dette afsnit giver et indblik i de forklarende variable som danner datagrundlaget for modeludvikling.

Data er indhentet fra følgende datakilder:

- Danmarks Statistik (DST)
- Landspatientregistret (LPR)
- Sundheds- og Omsorgsforvaltningen, Københavns Kommune
- Astma-Allergi Danmark

Data fra disse registre er transformeret til et udvalg af forklarende variable også kaldet features, der beskrives nedenfor i dette afsnit.

5.1 Demografi og uddannelse

Disse forklarende variable er udtaget fra Danmarks Statistik nærmere bestemt registrene *Befolkningen (BEF)* og *Uddannelse (UDDF)*.

Variabel	Beskrivelse
Alder	Alder
CIVST_T	Civilstand f.eks. gift eller enke
HUSTYPE_T	Husstandstype
IETYPE_T	Indvandrere, efterkommere, personer med dansk oprindelse
KOEN_T	Køn
STATSB_T_comb	Statsborgerskab
OPR_LAND_T_comp	Oprindelsesland
Uddannelse	Højest fuldførte uddannelse (UDD2015_L1_L5_T)

5.2 Vurdering af funktionsevnetilstand – Fælles Sprog III (FSIII)

Disse variable er udtaget fra Københavns Kommunes sundheds- og omsorgssystem Cura. Funktionsevnetilstandsvurderinger er beskrevet udførligt i dokumentet "OM FSIII – Tilstande og generelle oplysninger" (Sundheds og Omsorgsforvaltning, Københavns kommunes, 2018). Funktionsevnevurderinger foretages første gang når en borger bliver visiteret til sundheds- og omsorgsydelser eller til en plejehjemsplads og opdateres løbende.






Der indgår 30 spørgsmål i vurdering af borgernes funktionsevnetilstand, der er kategoriseret i fem områder (Tabel 4).

Tabel 4. Områder for funktionsevnetilstande FS III med eksempler.

Område	Eksempler
Praktisk opgave	Lave husligt arbejde, Lave mad
Samfundsliv	Have lønnet beskæftigelse
Egenomsorg	Vaske sig, Spise
Mobilitet	Løfte og bære, Udholdenhed
Mentale funktioner	Hukommelse, Overordnet kognitive funktioner

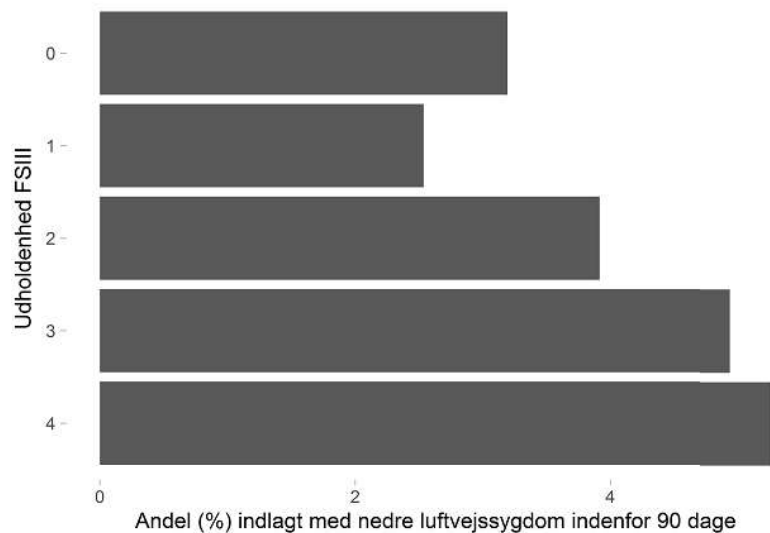
De 30 funktionsevnetilstande vurderes af

- borgeren selv
 - o begrænsning (oplever ingen begrænsninger = 0, oplever begrænsninger = 1).
 - o hvorvidt aktiviteten udføres selv (udføre selv = 0, udføre dele selv = 1, udføre ikke selv = 2).
- faglig medarbejder fra 0 – 4 (Figur 5).

FUNKTIONSEVNE -score				
 0	 1	 2	 3	 4
Ingen/ubetydelige begrænsninger	Lette begrænsninger	Moderate begrænsninger	Svære begrænsninger	Totale begrænsninger
Borgeren er selvstændig og har ikke behov for personassistance for at udføre aktiviteten.	Borgeren er den aktive part og kan med let personassistance udføre aktiviteten.	Borgeren er den aktive part og kan under forudsætning af moderat personassistance udføre aktiviteten.	Borgeren deltager og kan under forudsætning af omfattende personassistance udføre aktiviteten.	Borgeren er ude af stand til at udføre aktiviteten og har brug for fuldstændig personassistance for at udføre aktiviteten.

Figur 5. Guide til scoring af fællessprog III funktionsevne vurdering (Sundheds og Omsorgsforvaltning, Københavns kommunes, 2018)

Borgere og faglige medarbejdere kan vælge ikke at score alle funktionsevnetilstande. I disse tilfælde har man i denne rapport valgt at imputere med 0 (sætte scoren = 0) ud fra den antagelse at hovedparten af disse ikke vil opleve begrænsninger. Denne antagelse vil dog ikke holde for alle tilfælde og vil derfor kunne være årsag til støj i forudsigelsesmodelleringen.



Figur 6. Fagpersoners vurdering af udholdenhed FS III vs. andel (%) indlagt med nedre luftvejssygdom indenfor 90 dage blandt hjemmeplejemedtagere (N = 9017) i Københavns Kommune d. 1. januar 2018.

Figur 6 viser et eksempel på en sammenhæng mellem vurdering af en FSIII funktionsevnetilstand (udholdenhed) og andelen der bliver indlagt med nedre luftvejssygdom inden for 90 dage. Det ses at blandt hjemmeplejemedtagere, der er blevet vurderet som moderate til total begrænset (score 2-4) i udholdenhed er der en højere andel, der bliver indlagt med nedre luftvejssygdom end hjemmeplejemedtagere, der er blevet vurderet med ingen eller lette begrænsninger (score 0-1) i udholdenhed. Tabel 5 viser yderlige data bag Figur 6.

Tabel 5. Antal indlagt og ikke indlagt indenfor 90 dage med nedre luftvejssygdom versus fagpersoners vurdering af udholdenhed FS III d. 1. januar 2018 hos hjemmeplejemedtagere i Københavns Kommune.

	Fagpersoners vurdering af udholdenhed FS III				
	0 (%)	1 (%)	2 (%)	3 (%)	4 (%)
Indlagt	100 (3)	57 (2)	89 (4)	51 (5)	18 (5)
Ikke-indlagt	3028(97)	2187 (98)	2181 (96)	982 (95)	324 (95)

5.3 Vurdering af helbredstilstand – Fælles Sprog III (FSIII)

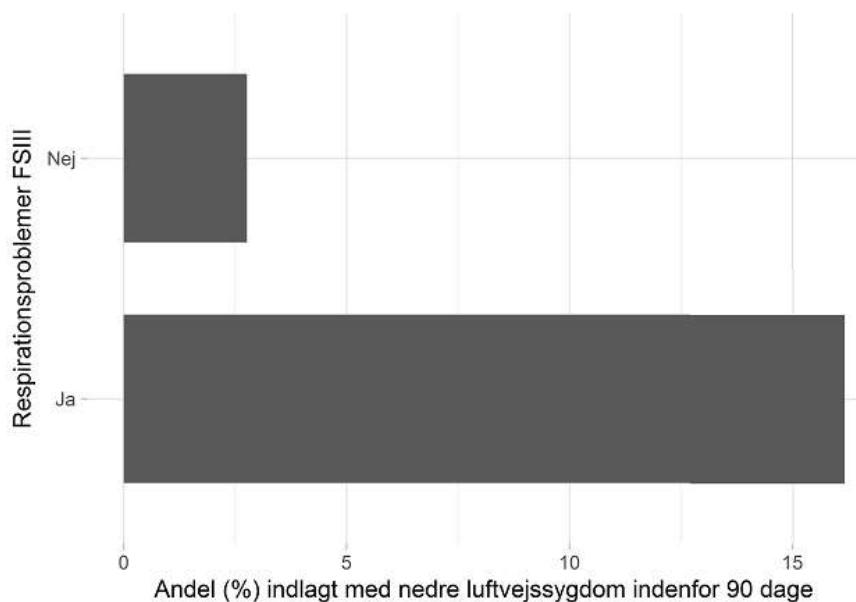
Disse variable er udtaget fra Københavns Kommunes sundheds- og omsorgssystem Cura. Helbredstilstandsvurderinger er beskrevet udførligt i dokumentet "OM FSIII – Tilstande og generelle oplysninger" (Sundheds og Omsorgsforvaltning, Københavns kommunes, 2018)

Der indgår 44 spørgsmål i vurderingen af helbredstilstande inden for 12 sygeplejefaglige problemområder og Tabel 6 viser nogle eksempler på disse. En helbredstilstandsvurdering vil kun fremgå, såfremt der er vurderet at være et problem. Således findes der her 44 forklarende variable med værdier 0 = intet problem eller 1 = problem. Helbredstilstandsvurdering indeholder også fritekstfelter, der uddyber problemet. Disse data har dog ikke kunne anvendes direkte grundet risiko for personfølsomme oplysninger.

Tabel 6. Sygeplejefaglige problemområder for fælles sprog III helbredstilstandsvurderingen

Område	Eksempler
Funktionsniveau	Problemer med personlig pleje
Bevægeapparat	Problemer med mobilitet og bevægelse
Ernæring	Problemer med væskeindtag, Problemer med overvægt
Hud og slimhinder	Problemer med tryksår
Kommunikation	Problemer med kommunikation
Psykosociale forhold	Mentale problemer
Respiration og cirkulation	Respirationsproblemer, cirkulationsproblemer
Seksualitet	Problemer med seksualitet
Smerter og sanseindtryk	Periodevise smerter, problemer med synssans
Søvn og hvile	Døgnrytmeproblemer
Døgnrytmeproblemer	Problemer med sygdomsindsigt, kognitive problemer
Udskillelse af affaldsstoffer	Problemer med vandladning

Figur 7 viser et eksempel på en sammenhæng mellem vurdering af en FSIII helbredstilstand (Respirationsproblemer) og andelen der bliver indlagt med nedre luftvejssygdom inden for 90 dage. Det ses at blandt hjemmeplejemodtagere, der er blevet vurderet til at have respirationsproblemer er der en højere andel (16%) der bliver indlagt med nedre luftvejssygdom end hjemmeplejemodtagere, der er blevet vurderet til ikke at have respirationsproblemer (3%).



Figur 7. Andel (%) indlagt med nedre luftvejssygdom indenfor 90 dage blandt hjemmeplejemodtagere (N = 9017) i Københavns Kommune d. 1. januar 2018, der er vurderet for respirationsproblemer FS III ($n_{nej} = 8528$, $n_{ja} = 489$).

5.4 Vurdering af boligindretning – Fælles Sprog III (FSIII)

Her findes 21 forhold der vurderes kan have en hæmmende eller fremmende effekt på en borgers funktionsevne f.eks. er badeværelsets indretning egnet til borgeren?

5.5 Genoptræning og forebyggelse seneste seks måneder

Der er medtaget 17 typer af genoptræningsforløb (data fra Københavns Kommune) inden for områderne vist i Boks 1. Genoptræning SUL (genoptræning efter sundhedsloven) er en fællesbetegnelse for alle forløb listet efterfølgende dvs. KOL, Geriatri, osv.

Boks 1. Typer af genoptrænings- og forebyggelsesforløb medtaget i modeludvikling.

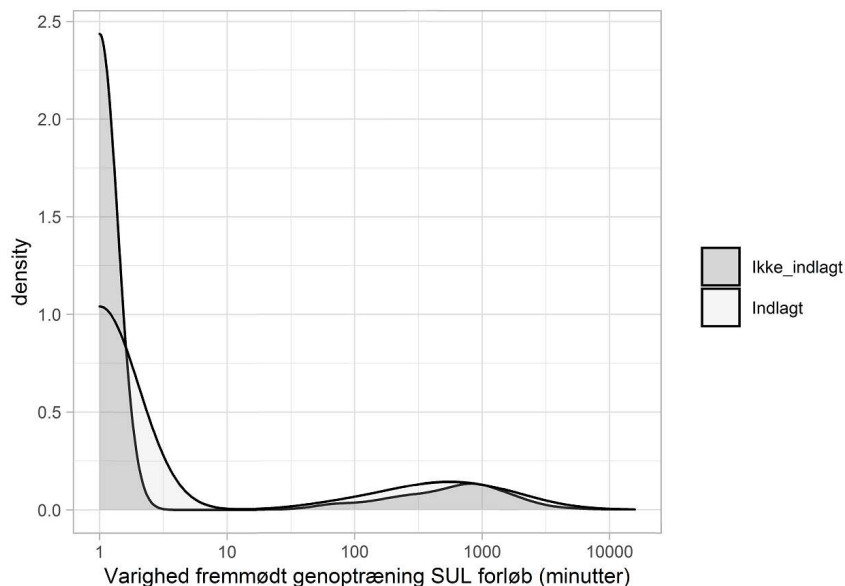
Ryg	Genoptræning SEL	Neurologi
Diabetes	Genoptræning SUL	Brud
Hjerte	KOL	Leddys
Kræft	Geriatri	Nyt knæ eller hofte
Stress	Ledoperationer	Urologi og gynækologi
GLAD tilbud	Cancer og organkirurgi	

Der er dannet forklarende variable som

- minutter fremmødt
- minutter aflyst

de seneste seks måneder fra forudsigelsestidspunktet inden for hver af de 17 typer. Det betyder at der totalt findes 34 forklarende variable beskrivende borgernes genoptræning og forebyggelse.

Figur 8 viser et eksempel på en sammenhæng mellem antal fremmødte minutter til genoptræning de seneste seks måneder og indlæggelse med nedre luftvejssygdom inden for 90 dage. Det ses at hjemmeplejemodtagere der bliver indlagt med nedre luftvejssygdom har haft en fordeling mod flere minutter genoptræning end hjemmeplejemodtagere der ikke bliver indlagt.



Figur 8. Densitetsplot der viser fordelingen af minutter fremmødt de seneste seks måneder til genoptræning efter sundhedsloven (SUL, logaritmisk skala) for hjemmeplejemodtagere der inden for 90 dage bliver hhv. indlagt (hvidt område) og ikke indlagt (gråt område) med nedre luftvejssygdom.

5.6 Visiteret tid til hjemme- og sygepleje

Der er lavet forklarende variable med *minutter visiteret tid per måned* på forudsigelsestidspunktet inden for de overordnede ydelser

- Praktisk hjælp
- Personlig pleje
- Sygepleje
- Total pleje (sum af ovenstående)

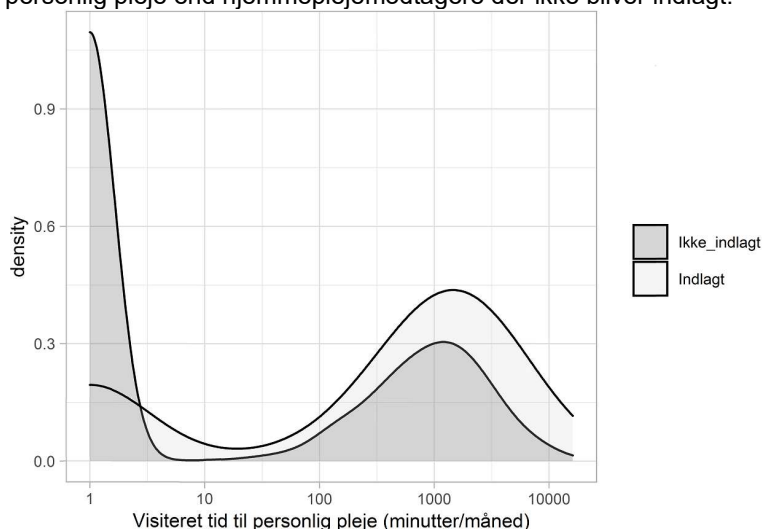
Endvidere er forholdet mellem visiteret tid på forudsigelsestidspunktet og hhv. 6 og 12 måneder inden for hver ydelse medtaget som forklarende variable idet et tidligere studie (Fournaise, 2017) indikerer, at en øgning i visiteret tid er en indikator for indlæggelsesrisiko.

Ydelsen *sygepleje* er endvidere underopdelt i 18 specifikke ydelsestyper. Der er oprettet 18 forklarende variable med minutter visiteret tid per måned på forudsigelsestidspunktet indenfor områderne vist i Boks 2.

Boks 2. Typer af sygepleje medtaget i modeludvikling

Mediceringivning	Demensforløbkoordination	Psykisk omsorg
Stomi og kateterpleje	Vejtrækningsbehandling	Instruktion, råd, vejledning
Kompressionsbehandling	Pleje af alvorlig syge	Prøvetagning
Behandling af tryksår	Sondeernæring	Forløbskoordination
Ernæringsterapi	Parenteral ernæring	Inkontinensbehandling
Sårbehandling	Helbredsmålinger	Andet

Figur 9 viser et eksempel på en fordeling i visiteret tid for dem der bliver henholdsvis indlagt (hvidt) og ikke indlagt (gråt) med dehydrering inden for 90 dage. Det ses at hjemmeplejemodtagere der bliver indlagt med dehydrering har haft en fordeling mod mere visiteret tid til personlig pleje end hjemmeplejemodtagere der ikke bliver indlagt.



Figur 9. Densitetsplot der viser fordelingen af visiteret tid til personlig pleje (minutter/måned, logaritmisk skala) for hjemmeplejemodtagere der inden for 90 dage bliver hhv. indlagt (hvidt område) og ikke indlagt (gråt område) for dehydrering.

5.7 Midlertidig ophold seneste seks måneder

Her findes forklarende variable som

- antal midlertidige ophold
- antal dage på midlertidigt ophold

for hver person de seneste seks måneder inden for 9 typer af ophold vist i Boks 3.

Boks 3. Typer af midlertidigt ophold medtaget i modeludvikling.

Rehabilitering – almen	Aflastning – almen	Akut plejeenhed
Rehabilitering – neuro	Aflastning – neuro	Palliativt ophold
Vurderingsplads – demens	Kort omsorgsophold	Palliativt – demens

5.8 Observationer

Observationer er opdelt i to grupper ud fra om svaret uddrages som fysiologisk målinger og diverse skalaer. Generelt er observationsdata mangelfulde, hvilket gør disse variable mindre brugbare til udvikling af forudsigelsesmodeller.

Fysiologiske målinger

Boks 4. Fysiologiske målinger anvendt.

Blodsukker	Puls	Temperatur
BMI	Respirationsfrekvens	
Systolisk blodtryk	Saturation procent	

Diverse skalaer

- Seneste afføringskema
- Seneste De Morton Mobility Index (DEMMI). Vurdering af mobilitet hos ældre.
- Seneste Gottfries-Bråne-Steen-skalaen (GBS). Vurdering af demens.
- Seneste Braden score. Vurdering af tryksår.
- Seneste Barthel-20 index. Vurdering af funktionsevne.

5.9 Vejr og pollen

Vejrdata findes for hver time fra hovedstadsregionen og følgende vejr-variable er udtaget:

- Median temperatur seneste 14 dage
- Total nedbør (mm) seneste 14 dage

Pollendata findes for hver dag fra hovedstadsregionen for pollentyperne birk, bynke, el, elm, græs og hassel. Følgende pollen-variable er udtaget for hver pollentype:

- Median pollen-tal seneste 14 dage
- Total pollen-tal seneste 14 dage

5.10 Indlæggelser adviseret til kommunen

Når en borger i Københavns Kommune modtager omsorgs- og/eller sundhedsydelse bliver der sendt en besked (advis) til kommunen i forbindelse med indlæggelser og udskrivelser fra hospital. I dette adviseringsystem findes der ikke systematisk information om indlæggelsesdiagnosen, hvilket kunne have været meget brugbart til forudsigelse af fremtidige indlæggelser. Hvis en borger desuden ikke har været bosat i Københavns Kommune i hele den definerede periode vil vedkommendes indlæggelsehistorik ikke fremstå som komplet. I stedet er der lavet forklarende variable for

- antallet indlæggelser
- antallet af sengedage

fra følgende perioder

- seneste måned
- seneste 6 måneder
- seneste 12 måneder
- seneste 18 måneder
- seneste 24 måneder

fra forudsigelsestidspunktet.

5.11 Indlæggelsehistorik fra landspatientregisteret

Historiske perioder

Gennem Landspatientregistret er udtaget forklarende variable om borgernes indlæggelsehistorik fire perioder fra forudsigelsestidspunktet

- seneste måned
- seneste 6 måneder
- seneste 5 år
- seneste 10 år

Optælling af begivenheder

Der er genereret forklarende variable svarende til forskellige typer af optællinger af begivenheder i ovenstående perioder

- **antal forløb:** fra indlæggelse til udskrivning fra hospitalet kaldes et forløb. En borger kan internt på hospitalet blive indlagt og udskrevet fra forskellige afdelinger, hvilket tæller som forskellige indlæggelser, men kun et forløb. Antallet af forløb i en periode vil således altid være mindre end eller lig med antallet af indlæggelser ($C_PATTYPE == 1$)
- **antal indlæggelser:** $C_PATTYPE == 1$
- **antal indlæggelsesdage:** indlæggelsesdage defineret som antal overnatninger
- **antal ambulante forløb:** planlagt hospitalsbesøg uden overnatning ($C_PATTYPE != 0$, $C_INDM == 2$)
- **antal skadestuebesøg:** akut hospitalsbesøg uden overnatning ($C_PATTYPE != 0$, $C_INDM == 1$)

ICD-10 kapitler

De forklarende variable for ovenstående optalte begivenheder er opgjort som total for perioden, men yderligere per ICD-10 kapitler. ICD er en forkortelse for International Classification of Diseases and Related Health Problems og ICD-10 er den tiende udgave af dette system. Systemet er defineret af WHO og grupperer sygdomme i 22 kapitler med tilhørende hovedgrupper og undergrupper som vist i Tabel 7 (Sundhedsdatastyrelsen, 2020)


Tabel 7. ICD-10 kapitler af sygdomme.

Kapitel	Titel
1	Infektiose inkl. parasitære sygdomme
2	Svulster
3	Sygdomme i blod og bloddannende organer og visse sygdomme, som inddrager immunsystem
4	Endokrine og ernæringsbetingede sygdomme samt stofskiftesygdomme
5	Psykiske lidelser og adfærdsmæssige forstyrrelser inkl. psykiske udviklingsforstyrrelser
6	Sygdomme i nervesystemet
7	Sygdomme i øje og øjenomgivelser
8	Sygdomme i øre og processus mastoideus
9	Sygdomme i kredsløbsorganer
10	Sygdomme i åndedrætsorganer
11	Sygdomme i fordøjelsesorganer
12	Sygdomme i hud og underhud
13	Sygdomme i knogler, muskler og bindevæv
14	Sygdomme i urin- og kønsorganer
15	Svangerskab, fødsel og barsel
16	Visse sygdomme, der opstår i perinatalperiode
17	Medfødte misdannelser og kromosomanomalier
18	Symptomer og abnorme fund ikke klassificeret andetsteds
19	Læsioner, forgiftninger og visse andre følger af ydre påvirkninger
20	Ydre sygdoms- og dødsårsager
21	Faktorer af betydning for sundhedstilstand og kontakter med sundhedsvæsen
22	Koder til specielle formål

Tidligere forebyggelige indlæggelser

Endelig er der opgjort antallet af indlæggelser og sengedage inden for de ni forebyggelige indlæggelser for hver periode.

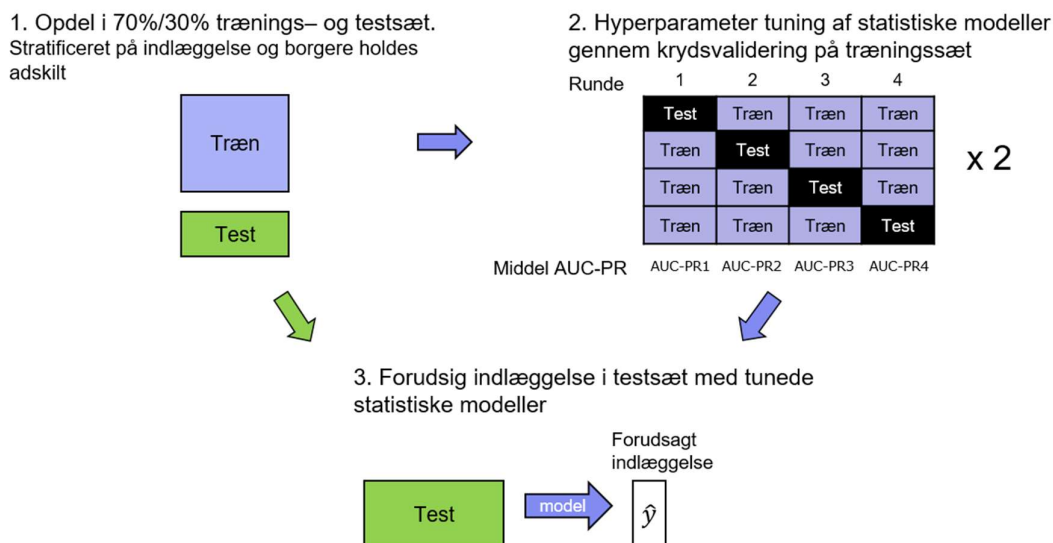
Figur 10 viser et eksempel på en sammenhæng mellem antal tidligere indlæggelser og fremtidige indlæggelser. Det ses, at når antallet af indlæggelser med nedre luftvejssygdom hos hjemmeplejemodtagere har haft de seneste 5 år stiger, så stiger andelen der vil blive indlagt med nedre luftvejssygdom de næste 90 dage ligeledes. Eksempelvis ses at blandt de hjemmeplejemodtagere der været indlagt 10 gange de seneste 5 år med nedre luftvejssygdom bliver ca. 25% indlagt inden for de næste 90 dage.



Figur 10. Antal indlæggelser med nedre luftvejs sygdom seneste 5 år blandt hjemmeplejemodtagere vs andel indlagt med nedre luftvejssygdom inden næste 90 dage.

6. Modeltræning

Når den afhængige variabel (indlæggelse ja/nej) og de forklarende variable (X) er klargjort, er næste skridt i modeludviklingen at fitte (eller træne) modeller, der beskriver sammenhænge mellem den afhængige variable og de forklarende variable. Figur 11 viser tre trin i modeltræningen, der beskrives yderligere i dette afsnit. Indledningsvist motiveres valget af statistiske modeller afprøvet i rapporten.



Figur 11. Flow diagram over udvikling af model til forudsigtelse af indlæggelse med forebyggelige diagnoser.

6.1 Valg og fravalg af statistiske modeller

De anvendte statistiske modeller i denne rapport er velbeskrevet i videnskabelige artikler (Wang & Ross, 2018) og lærebøger (Hastie, 2001) og derfor vil dette afsnit blot begrunde valget af afprøvede statistiske modeller.

Som beskrevet i afsnit 2 (Modeller til forudsigtelse af genindlæggelse i litteraturen) har hovedparten af de publicerede studier (68%) om forudsigtelsesmodellering af genindlæggelse anvendt logistisk regression. I denne rapport er logistisk regression også valgt som model hvor responset er binært som indlæggelse indenfor 90 dage (ja/nej). Motivation for at anvende logistisk regression er at modellen er lineær og giver god mulighed for at forstå effekten af de forklarende variable på sandsynligheden for indlæggelse. Idet logistisk regression ikke kan håndtere mange forklarende variable samtidigt, anvendes et elastisk net hvor en blanding af L1 og L2 regularisering (optimeret ved krydsvalideret hyperparameter tuning se afsnit 6.3) for at skrumpe koefficienters størrelse og/eller antal (Hastie, 2001). Denne regularisering reducerer risikoen for overfittede modeller og L1 regulariseringen giver indbygget variable selektion, hvilket giver simple og produktionsvenlige modeller. Der er ikke valgt at tilføje interaktioner mellem forklarende variable i logistisk regression, idet der er >700 variable hvilket giver et enormt antal to-faktor interaktioner. Dette kunne muligvis løses med backtracking LASSO

(Shah, 2016), men dette er ikke forfulgt videre i denne rapport. Der er heller ikke valgt at transformere forklarende variable ud fra systematiske residual plots. Et ikke anvendt men interessant alternativ til transformation kunne være generaliserede additive modeller (GAM) regulariseret med elastisk net, hvor ikke-linearitet modelleres, hvilket giver nogle gode fortolkningsbare modeller.

Beslutningstræer kan håndtere interaktioner og ikke-lineære sammenhænge til responset uden at skulle præspecifere det i modellen eller transformere variable (James, Witten, Hastie, & Tibshirani, 2013) som logistisk regression skal hjælpes til af brugeren. Dette er en af grundene til at træmodellerne random forest og extreme gradient boosting er afprøvet i denne rapport.

Udfordringen med få indlagt i forhold til ikke-indlagte (klasseubalance), har undervejs i modeludviklingen været forsøgt optimeret ved at up-sample de indlagt eller ved at give indlagt med større vægt i optimeringen af loss funktionen. Det har ikke givet bedre modeller, men eller dog heller ikke undersøgt systematisk i den afsluttende del af modelleringen.

En form for ensemble stacking har været forsøgt uden forbedringer i modellerne. Med denne tilgang udvikles modeller for alle diagnoser på 30% data borgerne. Disse modeller blev herefter anvendt på andre 40% af borgerne, hvorved der fremkom en prædikteret sandsynlighed for indlæggelse for hver diagnose. De prædikterede sandsynligheder for indlæggelse blev anvendt som nye forklarende variable sammen med resten af de oprindelige forklarende variable på disse 40% af borgerne. De endelige modellens forudsigelse blev evalueret på de resterende 30% af borgerne, dog uden forbedringer i modellerne.

6.2 Test- og træningssæt opdeling

Den forberedte datamatrice opdeles i to dele:

- et træningssæt som statistiske modeller udvikles på
- et testsæt hvormed den endelige models forudsigelsesevne evalueres.

Opdelingen foretages stratificeret mht. indlæggelse. Stratificeret opdeling betyder at opdelingen foretages således at andelen af indlagte er bliver ens i både trænings- og testsæt. Endvidere foretages opdelingen således at en borger kun findes i enten trænings- eller testsæt for at reducere risikoen for overfittede modeller med overoptimistisk forudsigelsesevne. I denne rapport er opdelingen foretaget med 70% af borgerne i træningssættet og 30% i testsættet.

En svaghed ved evalueringen af denne rapporters modeller er at kun et års data er til rådighed og således testes modellernes forudsigelse med data fra samme år. Når man ønsker at kende hvor godt modellerne vil forudsige fremadrettet ville det være mere robust /realistisk at teste modellerne på data fra et andet år end det år modellen er trænet på. Modellernes forudsigelse når samme års data testes kan være for optimistisk, i forhold til hvor god forudsigelsen vil være i fremtiden.

6.3 Søgning efter bedste model med hyperparameter gridsøgning og krydsvalidering

På træningssættet udvikles statistiske forudsigelsesmodeller. De statistiske metoder anvendt i denne rapport har alle såkaldte hyperparametre. Hyperparametre er parametre der indstilles af modeludvikleren i modsætning til parametre som estimeres ud fra data. En skæring og hældning bestemt ved lineær regression er eksempler på parametre estimeret ud fra data.

Evalueringemetrikken AUCPR

Hyperparameter indstilling (eng. tuning) i dette projekt optimeres med hensyn til at opnå den mest sikre forudsigelse. Dette optimeringskriterie vægtes i dette projekt højere end at kunne forklare hvilke og hvordan de forklarende variable har sammenhæng til indlæggelse og det har haft betydning for hvilke statiske metoder der er anvendt. Den mest sikre forudsigelse evalueres vha. metrikken *area under the precision recall curve* (AUCPR). I binære klassifikationsmodeller anvendes ofte den relaterede og mere velkendte metrik *area under the receiver operating characteristic curve* (AUC eller AUCROC), men som pointeret af Saito & Rehmsmeier (2015) er AUCROC misvisende når forholdet mellem klasser ubalanceret. Evalueringemetrikken AUCPR er således netop valgt idet forholdet mellem borgere, der bliver indlagt, og borgere, der ikke bliver indlagt, er stærkt ubalanceret. AUCPR er beskrevet mere detaljeret i Saito & Rehmsmeier (2015), men jo højere AUCPR (maksimum 1) desto mere sikker kan en model forudsige. En model med en AUCPR lig med eller mindre end andel indlagt f.eks. AUCPR = 0.025 (2,5%) svarer til en model der forudsiger tilfældigt dvs. ikke brugbart. En models AUCPR skal således ses i forhold til andelen af indlagte.

Hyperparameter tuning

Begrebet *hyperparameter tuning* dækker over processen at afprøve forskellige indstillinger af hyperparametre og vælge den indstilling hvor evalueringemetrikken er bedst, hvilket i denne rapport er den højeste AUCPR. Tabel 8 viser de hyperparametre tunet i denne rapport.

Eksempelvis vil der for den statistiske metode random forest blive afprøvet hvilken effekt forskellige indstillinger af hyperparameteren $mtry$ har på forudsigelse. $mtry$ er antallet af forklarende variable tilfældigt udtrukket ved hver split i de mange beslutningstræer som random forest algoritmen danner. En typisk værdi af $mtry$ er kvadratroden af antallet af forklarende variable p (Probst, Wright, & Boulesteix, 2018), hvilket i denne rapport er 26 ($\approx\sqrt{700}$).

Tabel 8. Hyperparametre tunet for statistiske modeller i denne rapport

Statistisk model (R-pakke)	Hyperparameter afprøvet	Værdier afprøvet
Random forest (ranger)	$mtry$	$(10\%, 50\%, 100\%)*\sqrt{p}$
	min.note.size	13
Logistisk regression regulariseret med elastisk net (glmnet)	alpha	0, 0.5, 1
	lambda	$10^{(-7.0, -6.9, \dots, 1.9, 2.0)}$
Extreme gradient boosting (caret)	nrounds	10, 15, ..., 175, 180
	max depth	2, 3, 4
	Eta	0.001, 0.01, 0.1
	Gamma	5, 10
	columns sample by tree	0.1, 0.4
	min child weight	2
	sub sample	0.2, 0.6

I rapportens modellering er valgt at afprøve følgende sekvens af $mtry$ $(10\%, 50\%, 100\%)*\sqrt{p}$ hvilket bliver til $mtry$ 3, 13 og 26. Den $mtry$ der giver den model med den højeste AUCPR vælges til anvendelse på test sættet og kan afhænge af hvilken forebyggelig diagnose og borgergruppe der hyperparameter tunes.

Krydsvalidering

Hvis en model trænes på samme data som den efterfølgende evalueres på, vil forudsigelse ofte være for optimistisk (overfittet) i forhold til hvordan modellen virker på nyt data. Dette forhold gælder også ved valg af hyperparameter dvs. den bedste hyperparameter indstilling kan være forskellig om der anvendes samme data eller nyt data. Dette problem overkommes ved at krydsvalidere ved 4 folds opdeling gentaget 2 gange som illustreret i Figur 11. Ved første gentagelse opdeles borgerne tilfældigt i fire lige store grupper (statificeret mht. indlæggelse) også kaldet *folder*. I krydsvalideringens første runde holdes første fold ude af modeltræning og modellens AUCPR evalueres på den udeladte fold. Dette gøres alle de udvalgte hyperparameter værdier for den pågældende model (Tabel 8). Samme procedure gentages i anden runde hvor anden fold holdes uden for osv. Efter fjerde runde er afsluttet starter anden gentagelse hvor borgerne på ny tilfældigt opdeles i fire lige store grupper og samme procedure gentages med fire runder. Afslutningsvist tages gennemsnittet af AUCPR for de 4x2 runder for hver hyperparameter indstilling $AUCPR_{hyp_middel}$ og den hyperparameter indstilling med den højeste $AUCPR_{hyp_middel}$ vælges som den optimale.

Når data matricen er stor som i dette projekt bliver krydsvalidering en tidskrævende proces, idet modellering gentages $n_{fold} * n_{gentagelser}$ gange, hvilket i dette projekt er 8 gange. Idet de enkelte runder er uafhængige af hinanden også kaldet *embarrassingly parallel* kan de startes samtidig på hver deres kerne. R-pakken *foreach* er anvendt til at kode parallel processering af krydsvalideringen, hvilket reducerer processeringstiden en del.

Endvidere kan random forest og extreme gradient boosting paralleliseres i fitningen ved at fordele træbygning på flere kerne, hvilket også er udnyttet for at bringe processeringstiden ned.

6.4 Forudsig indlæggelse i testsæt med tunede statistiske modeller

De tunede statistiske modeller anvendes på testsættet for at evaluere hvor godt modellerne vil klare sig på nye data, der ikke har været involveret i modeludviklingen. Nærmere bestemt estimerer den trænedte algoritme en sandsynlighed for indlæggelse og her skal vælges en grænseværdi for ved hvilken sandsynlighed en borger klassificeres som fremtidig indlagt.

Denne grænseværdi vælges ved (gennem en såkaldt Precision-Recall kurve, se afsnit 6.6) at sammenholde de forudsagte indlæggelsessandsynligheder for borgeren med 'sandheden', altså sandheden om, hvorvidt borgeren rent faktisk blev indlagt inden for forudsigelseshorisonten. Valget af grænseværdi er et kompromis mellem hvor stor en andel af dem, der blive indlagt, man ønsker at opspore (recall), og hvor god præcision (precision) skal være. Det er ikke alle de borgere, der bliver forudsagt til at blive indlagt, der reelt bliver indlagt. Præcision (precision) udtrykker andelen, der reelt bliver indlagt blandt de, der bliver forudsagt til at blive indlagt. Generelt falder præcision (precision) med recall (opsporingsgraden). En lav præcision er ensbetydende med et stort antal falske positive, hvilket betyder at et stort antal borgere unødvendigt bliver markeret som i risiko for indlæggelse. Valg af recall og dertilhørende forudsigelsespræcision afhænger af forudsigelsens anvendelse og skal derfor træffes sammen med slutbrugere. Det er vurderet (af forfatterne) at modeller skal kunne opspore minimum 20% (recall) af de der faktisk bliver indlagt indenfor forudsigelseshorisonten. Ud fra Precision-Recall kurven kan det aflæses, hvilken præcision 20% recall svarer til.

6.5 Håndtering af årstidsvariation

Andelen af borgere indlagte med nedre luftvejssygdomme og dehydrering afhænger er fundet afhængig af årstiden (se 4.3 Årstidsvariation i forebyggelige indlæggelser). Rent intuitivt giver det også mening at risikoen for nedre luftvejssygdomme er størst om vinteren, hvor folk samles indenfor og risikoen for dehydrering er størst om sommeren hvor temperaturen er højere.

Hvis en forudsigelsesmodel udviklet alene med data fra et forudsigelsestidspunkt 1. januar anvendes på borgere 1. juli vil den forudsagte risiko for indlæggelse med nedre luftvejssygdom blive estimeret for højt og den forudsagte risiko for indlæggelse med dehydrering vil blive estimeret for lavt. For at forbedre forudsigelsen kan årstidsafhængigheden forsøges indbygget i modellerne med forskellige tilgange:

- **12 månedsmoeller:** her bygges en model for hver måned med udgangspunkt i f.eks. 1. januar, 1. februar, ..., 1. december. Når en forudsigelse skal laves på en borgergruppe vælges den månedsmoel der ligger tættest på datoen forudsigelsestidspunktet.
- **Én årsmoel:** her sammensættes data fra 12 forudsigelsestidspunkter f.eks. 1. januar, 1. februar, ..., 1. december til én stor datamatrice, hvor der oprettes en månedsvaibel. Efterfølgende bygges én model på denne sammensatte data matrice. En *udfordring* ved denne tilgang er at samme borger eksistere flere gange i datamatricen, men ved forskellige tidspunkter. Dette kræver særlig håndtering ved valideringen af forudsigelsesevnen samt ved søgning efter bedste hyperparameter kombination med krydsvalidering. Endvidere kan en ulempe ved en årsmoel være at månedsmoeller muligvis bedre kan fange

sammenhænge med indlæggelse og forklarende hvis disse sammenhænge af særligt sæsonafhængig. En *fordel* ved denne tilgang er dog at problemet med meget få indlagte ved nogle af de forebyggelige diagnoser reduceres idet sammensætning af data fra flere forudsigelsestidspunkter vil øge antallet indlagte. Dette muliggør at kunne bygge forudsigelsesmodeller for flere diagnoser og vil kunne mindske den usikkerhed der er forbundet med estimater af forudsigelsesevnen.

6.6 Hvad er precision og recall?

Precision (præcision) og recall (opsporingsgrad) er termer der anvendes til beskrive hvor godt en model forudsiger den begivenhed – her indlæggelse - den er udviklet til at forudsige.

Boks 5. Definition af precision og recall.

Precision	
Andel af <i>faktisk fremtidig indlagte</i> (sande positive) ud af de <i>forudsagt indlagte</i> (sande + falske positive)	$\frac{\text{antal faktisk fremtidig indlagt}}{\text{antal forudsagt indlagt}} * 100\%$
Recall	
Andel af <i>opsporet fremtidige indlagte</i> modellen finder ud af <i>total antal fremtidig indlagte</i>	$\frac{\text{antal opsporet fremtidig indlagt}}{\text{antal fremtidig indlagt}} * 100\%$

Eksempel precision:


*En model forudsiger at 200 borgere bliver indlagt inden for 90 dage. 50 borgere af disse 200 borgere indlægges indenfor 90 dage. Modellens precision er 25% (=50/200*100%)*

Eksempel recall:

*250 borgere bliver indlagt indenfor 90 dage. En model opspore 50 af disse 250. Modellens recall er 20% (=50/250*100%).*

Precision og recall afhænger hinanden

For mange modeller kan man uddrage en forudsagt sandsynlighed for indlæggelse \hat{p}_{indlagt} der kan antage en værdi fra 0 - 100%. Ved at vælge en klassifikationsgrænseværdi mellem 0 og 100% kan man skrue på hvor mange der klassificeres som *forudsagt indlagt* og *forudsagt ikke indlagt*. Denne klassifikationsgrænseværdi påvirker recall og precision. Hvis grænseværdien sænkes stiger recall, idet flere opspores af de fremtidig indlagte. Dette sker dog på bekostning af precision som falder, idet andelen af faktisk fremtidig indlagt ud af antal forudsagt indlagt falder. Praktisk talt betyder det at andelen af borgere med en alarm på sig omkring fremtidig indlæggelse stiger og ved et vist punkt vil antallet af borgere med en alarm stige til et niveau der ikke er praktisk muligt at forhold sig til for Københavns Kommunes sundheds- og omsorgsforvaltning.



Figur 12. Eksempel på precision-recall kurve for forudsigelsesmodellen for 90 dages indlæggelse med nedre luftvejssygdom blandt plejehjemsboere.

Figur 12 viser et eksempel på en såkaldt precision-recall kurve for en klassifikationsmodel, hvor sammenhængen mellem præcision og recall ses. Kurven viser f.eks. at ved 20% recall (opsporingsgrad) er præcisionen ca. 28%, ved 50% recall er præcisionen ca. 12% og ved 5% recall er præcisionen ca. 50%.

Precision-recall (PR) kurven er relateret til *receiver operating characteristic* (ROC) kurven, men ROC er mindre relevant at kigge på når forholdet mellem indlagt og ikke-indlagt er stærkt ubalanceret (Saito & Rehmsmeier, 2015), som det er tilfældet for denne rapporters modeludvikling.

7. Årsmodele for indlæggelsesforudsigelse

Dette afsnit beskriver udvikling af modeller til forudsigelse af forebyggelige indlæggelser med den såkaldte årsmodeltilgang (se nærmere i afsnit 6.5 Håndtering af årstidsvariation) samt resultater for modellernes forudsigelsesevne.

Afsnittet indeholder følgende figurer og tabeller der illustrerer modeludviklingen og resultaterne:

- Et overordnet flowdiagram af modeludviklingen opdelt i syv trin er vist i Figur 13.
- Forudsigelsesevnen for modeller for hver forebyggelig diagnose når alt tilgængeligt data har været anvendt ses i Tabel 10 (hjemmeplejemodtagere) og Tabel 11 (plejehjemsbeboere).
- Forudsigelsesevnen for modeller for hver forebyggelig diagnose når kun data tilgængeligt for Københavns Kommune anvendes i modeludviklingen ses i Tabel 12 (hjemmeplejemodtagere) og Tabel 13 (plejehjemsbeboere).
- Kompromiset mellem antal alarmerede personer og antal opsporede fremtidig indlagte illustreres i Figur 14.
- Top 15 mest betydende features for forudsigelse af nedre luftvejssygdom ses i Figur 17 (alt data) og Figur 18 (data tilgængeligt for Københavns Kommune).

7.1 Procedure for modeludvikling

Modeludvikling med årsmodeltilgangen er opdelt i syv trin (Figur 13), der igen kan opdeles i tre faser. Fase I: dataforberedelse (trin 1-3), Fase II: modeltræning (trin 4-5), Fase III: testsæt forudsigelse (trin 6-7).

Fase I – dataforberedelse

- 1) Sammensæt data fra 12 forudsigelsestidspunkter:** Under årsmodeltilgangen sammensættes data fra 12 forudsigelsestidspunkter dækkende et år fra 1.oktober 2017, til 1. september 2018. Dvs. at en borger kan findes op til 12 gange i den sammensatte datamatrice, ofte med lille variation i variable mellem forudsigelsestidspunkter. Et eksempel på en ændring i en forklarende variabel kan være en borgers visiterede tid til hjemmepleje (min/måned) som stiger gennem et år, hvilket kan være prædikativ for risikoen for indlæggelse.
- 2) Ekskluder variable der ikke findes i hele perioden:** Ved udvikling af årsmodeller er der kun inkluderet variable der findes på alle forudsigelsestidspunkter. En konsekvens af at sammensætte data fra forskellige forudsigelsestidspunkter – her et år – er at nogle forklarende variable ikke findes på alle tidspunkter. Det kan ske når dokumentationspraksis ændres i kommunen hvorved variable udgår og andre kommer til.

- 3) **Ekskluder variable med nul eller nær-nul varians:** Forklarende variable med nul varians (kun én værdi findes) eller nær-nul varians (næsten kun samme værdi findes) ekskluderes. Nulvariens variable har ingen forklaringskraft. Nær-nul varians variable har ofte heller ingen forklaringskraft. Endvidere kan kategoriske nær-nul varians variable besværliggøre test- og krydsvalidering, idet alle observationer fra et kategori-level kan havne i valideringssættet.

Fase II modeltræning

- 4) **Opdel i 70%/30% trænings- og testsæt.** Den forberedte datamatrice opdeles i to dele: et træningssæt som machine learning modeller udvikles på og et testsæt hvormed den endelige models forudsigelsesevne evalueres. Opdeling foretages stratificeret mht. diagnose således at andelen af indlagte er ens i både trænings- og testsæt. Endvidere foretages opdelingen således at data for alle (op til) 12 forudsigelsestidspunkter for en borger kun findes i enten træningssæt eller testsæt for at reducere risikoen for overfittede modeller med overoptimistisk forudsigelsesevne.
- 5) **Hyperparameter tuning af statistiske modeller gennem krydsvalidering på træningssæt.** Det trænes tre typer statistiske modeller der alle har såkaldte hyperparametre, som kan have indflydelse på forudsigelsesevnen. Derfor tunes hyperparametrene for at finde den bedste forudsigelsesevne, der bestemmes via krydsvalidering (4 fold, gentaget 2 gange), hvor opdelingen ligeledes foretages stratificeret og således at borgere kun findes i en fold. Den optimale hyperparameter indstilling defineres som den indstilling der resulterer i den højeste gennemsnitlige *area under the precision recall curve* (AUCPR) mellem de udeladte folder. Metrikken AUCPR er valgt idet forholdet mellem borgere, der bliver indlagt, og borgere, der ikke bliver indlagt, er stærkt ubalanceret (Saito & Rehmsmeier, 2015). De anvendte machine learning algoritmer og de tunede hyperparametre er:

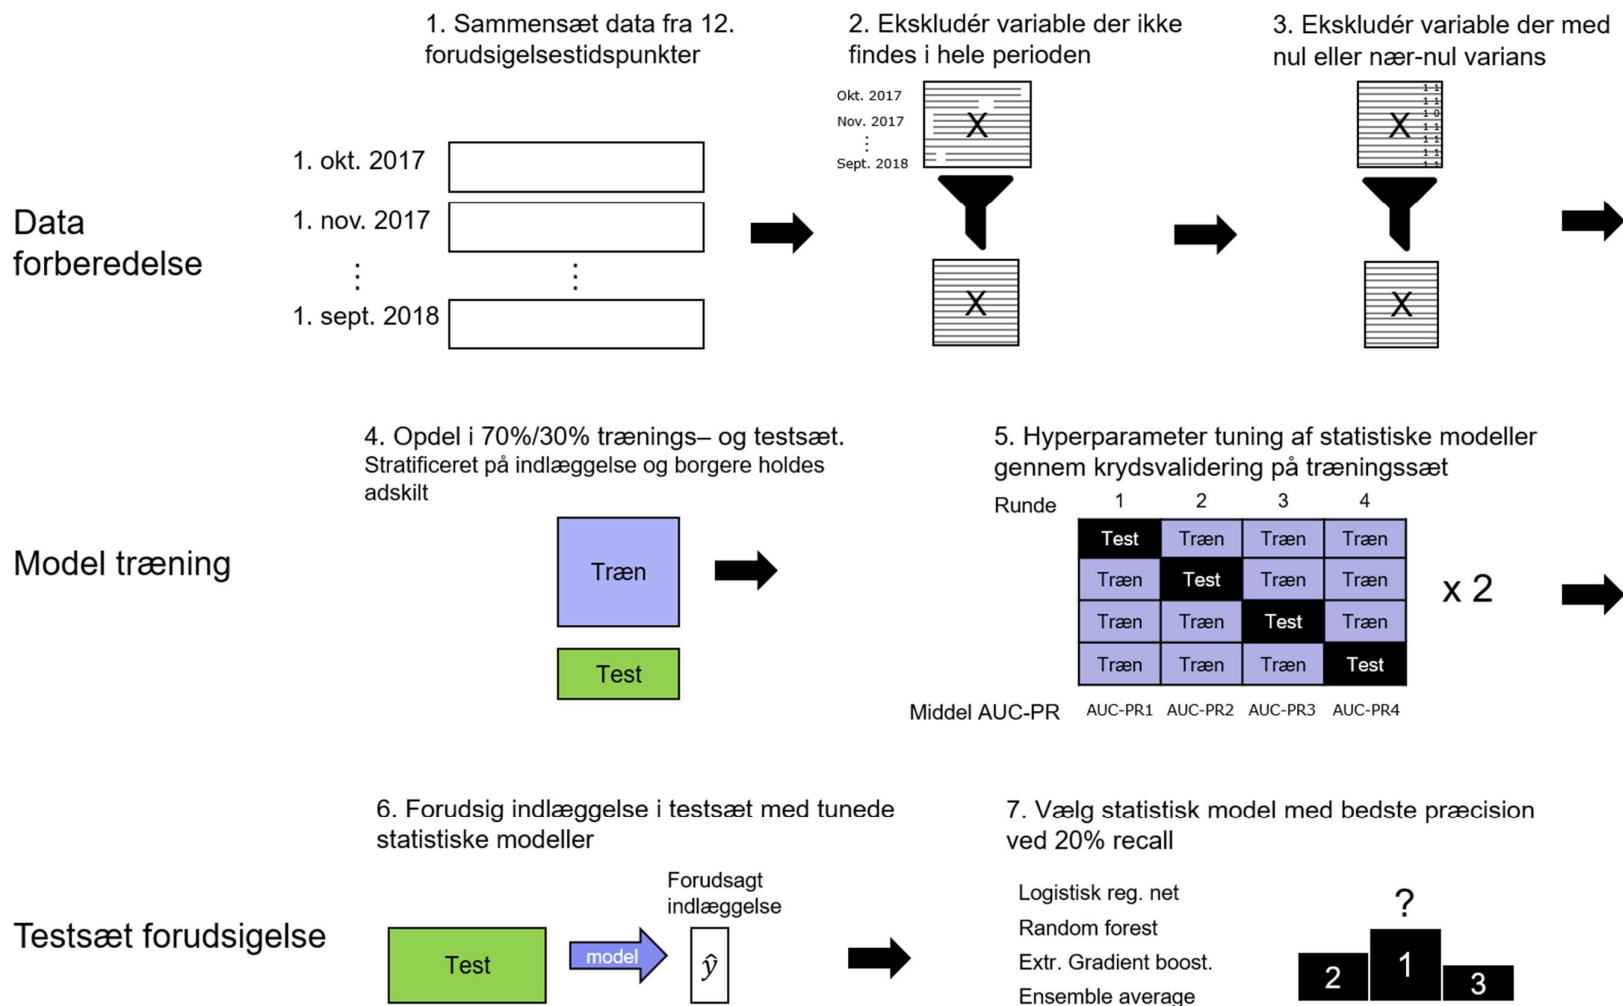
- **logistisk regression regulariseret med elastisk net:** alpha og lambda
- **random forest:** mtry
- **extreme gradient boosting:** nrounds, eta, max_depth, gamma, subsample

Fase III: testsæt forudsigelse

- 6) **Forudsig indlæggelse i testsæt med tunede statistiske modeller:** De tunede statistiske modeller anvendes til forudsigelse af indlæggelse af borgere i testsættet. Nærmere bestemt estimerer den trænedte algoritme en sandsynlighed for indlæggelse og her skal vælges en grænseværdi for ved hvilke sandsynlighed en borger klassificeres som fremtidig indlagt. Denne grænseværdi vælges ved (gennem en såkaldt Precision-Recall kurve) at sammenholde de forudsagte indlæggelsessandsynligheder for borgeren med 'sandheden', altså sandheden om, hvorvidt borgeren rent faktisk blev indlagt inden for forudsigelseshorisonten. Valget af grænseværdi er et kompromis mellem hvor stor en andel af dem, der blive indlagt, man ønsker at opspore (recall), og hvor god præcision (precision) skal være. Det er ikke alle de borgere, der bliver forudsagt til at blive indlagt, der reelt bliver indlagt. Præcision (precision) udtrykker andelen, der reelt bliver indlagt

blandt de, der bliver forudsagt til at blive indlagt. Generelt falder præcision (precision) med recall (opsporingsgraden). En lav præcision er ensbetydende med et stort antal falske positive, hvilket betyder at et stort antal borgere unødvendigt bliver markeret som i risiko for indlæggelse. Valg af recall og dertilhørende forudsigelsespræcision afhænger af forudsigelsens anvendelse og skal derfor træffes sammen med slutbrugere. Det er vurderet (af forfatterne) at modeller skal kunne opspore minimum 20% (recall) af de der faktisk bliver indlagt indenfor forudsigelseshorisonten. Ud fra Precision-Recall kurven kan det aflæses, hvilken præcision 20% recall svarer til.

- 7) **Vælg statistiske model med bedste præcision ved 20% recall:** For hver diagnosemodel vælges den af de tre statistiske modeller der har højeste forudsigelsespræcision ved 20% recall på testsættet. Her tages ligeledes et gennemsnit af de tre tunede modellers forudsigelsessandsynlighed (ensemble average) der således evalueres som en fjerde model.



Figur 13. Flowdiagram over udvikling af model til forudsigelse af indlæggelse med forebyggelige diagnoser.

7.2 Resultater

Tabel 10 (hjemmeplejemodtagere) og Tabel 11 (plejehjemsbeboere) viser forudsigelsesevnen af modeller for hver forebyggelig diagnose rangeret efter forudsigelsespræcision. Forudsigelsesevnen, eller modellens performance, er udtrykt ved kolonne 3-6 i Tabel 10 og Tabel 11.

Præcision er uddraget fra den såkaldte *Precision-Recall* kurve for modellen ved 20% recall (opsporingsgrad). Det ses af Tabel 10 at blandt de ni diagnosemodeller har modellen for nedre luftvejssygdom den højeste forudsigelsespræcision på 28,6% for 20% recall (opsporingsgrad), hvilket betyder at 28,6% af borgere der forudsiges indlagt kan forventes at blive indlagt med nedre luftvejssygdom indenfor 90 dage.

Tabel 10 viser hvad denne forudsigelsesevne betyder i forventet antal per 10.000 hjemmeplejemodtagere, som er det omtrentlig antal hjemmeplejemodtagere der er i Københavns Kommune på et givet tidspunkt. Med en 90 dages incidens af indlæggelse med nedre luftvejssygdom på 2,6% betyder dette at der forventes 260 ($=0,026 \cdot 10.000$) indlagt indenfor 90 dage.


- En 20% recall (opsporingsgrad) betyder at 52 ($=0,2 \cdot 260$) fremtidig indlagte opspores af modellen og 28,6% præcision betyder 182 ($=52/0,286$) forudsiges indlagt for opspore disse 52.
- Samme model kan have en opsporingsgrad på f.eks. 30%, men her viser Precision-Recall kurven at præcisionen falder til 21,7%. En 30% opsporingsgrad betyder at 78 ($=0,3 \cdot 260$) fremtidig indlagte opspores af modellen og 21,7% præcision betyder 359 ($=78/0,217$) forudsiges indlagt for opspore disse 78, hver gang en forudsigelse foretages (Tabel 9). Dette er muligvis et for højt antal borgere for Sundheds- og Omsorgsforvaltningen af reagere på givet antallet af opsporet fremtidigt indlagt.
- Evt. kunne de 182 alarmeret angives som **rød** (høj risiko, høj præcision) og de 177 ($=359-182$) alarmeret angives som **gul** (mellem risiko, mellem præcision).

Tabel 9. Forudsigelsesevne af model til opsporing af indlæggelser med nedre luftvejssygdom blandt hjemmeplejemodtagere med 10%, 20% og 30% recall.

Recall (%)	Præcision (%)	Antal per 10.000 hjemmeplejemodtagere indenfor 90 dage	
		Opsporet	Forudsagt indlagt
10	34,5	26	75
20	28,6	52	182
30	21,7	78	359
50	10,0	130	1300

Disse overvejelser handler i høj grad om hvor mange det er praktisk muligt for sundheds- og omsorgsforvaltningen at reagere på. Man må forvente at 10.000 hjemmeplejemodtagere administreres i mindre organiserede enheder af f.eks. 500 hjemmeplejemodtagere. Givet en 90 dages incidens på 2,6% for indlæggelser forårsaget af nedre luftvejssygdom indlæggelser er det forventet antal per 500 hjemmeplejemodtagere 13 borgere. Ud af disse forventes 3 opsporet

(20% recall) og 9 forventes forudsagt indlagt (28,6% præcision). 9 alarmeret virker ikke som mange borgere at reagere på i en organisatorisk enhed med 500 hjemmeplejemodtagere.



Figur 14. Antal forudsagt indlagt (alarmeret) versus antal faktisk fremtidig indlagte opsporet med nedre luftvejssygdom indenfor 90 dage per 10.000 hjemmeplejemodtagere i Københavns Kommune. Nederst plot er et zoom udsnit fra øverste plot.

Figur 14 viser sammenhængen mellem antal alarmeret og opsporingsgrad for modellen for nedre luftvejssygdom. F.eks. kan det aflæses at der kan opspores ca. 125 af de 260 forventede indlagte (recall = $125/260 \cdot 100\% = 48\%$) ved at udvælge de 1000 borgere med den højeste forudsagte sandsynlighed for indlæggelse.

De resterende diagnosemodeller for hjemmeplejemodtagere (Tabel 10) har meget lav forudsigelsespræcision (< 5%) ved opsporingsgrad på 20%, hvilket betyder antallet af forventet alarmeret er meget højt og vurderes ikke praktisk anvendeligt at reagere på i forhold til antal opsporet.

Tabel 11 viser diagnosemodellerne for *plejehjemsbeboere* i Københavns Kommune. Modellerne er rangeret efter 90 dages forudsigelsespræcision ved 20% recall (opsporingsgrad). Præcisionen er højest for indlæggelse med nedre luftvejssygdomme på 13,6%, hvilket er noget

mindre præcision end den samme diagnosemodel for hjemmeplejemodtagere og vurderes for lavt til praktisk anvendelse. De resterende diagnosemodeller har ligeledes meget lav præcision.

Med same procedure som beskrevet i Figur 13 er der blevet udviklet modeller kun baseret på data tilgængeligt for København kommune, hvilket ekskluderer data fra landspatientregistret (LPR) omkring tidligere indlæggelser. Resultaterne fremgår af Tabel 12 (hjemmeplejemodtagere) og Tabel 13 (plejehjemsboere).

Det ses af Tabel 12 at blandt de ni diagnosemodeller har modellen for nedre luftvejssygdom den højeste præcision på 14,5% for en 20% recall (opsporingsgrad). Dette betyder at 52 fremtidig indlagte opspores af modellen og at 358 forudsiges indlagt for opspore disse 52. Det vurderes at dette antal af forudsagte indlagte er for højt, til praktisk set at kunne reagere på i Købehavns Kommune givet opsporingsgraden.

Tabel 10. 90 dages forudsigelsesevne af modeller af forebyggelige diagnoser blandt hjemmeplejemodtagere i Københavns Kommune. Diagnosemodellernes forudsigelsesevne er angivet som præcision (%) ved 20% recall. Forventet antal indlagte (gennemsnit i træningssæt), opsporet af indlagte og alarmeret af modellen per 10.000 hjemmeplejemodtagere. Manglende tal angiver < 5 borgere bliver gennemsnitligt indlagt indenfor 90 dage, hvilke er maskeret jvf. Danmarks Statistiks regler om mikrodata.

Forebyggelig Diagnose	Algoritme med højeste præcision*	Præcision (%) [*]	Forventet antal per 10.000 hjemmeplejemodtagere indenfor 90 dage		
			Indlagte	Opsporet ^{**}	Forudsagt indlagt ^{**}
Nedre luftvejssygdomme	Ensemble average	28,6	260	52	182
Dehydrering	Random forest	4,7	95	19	408
Blærebetændelse	Log. regr. Net	2,8	42	8	305
Forstoppelse	Extr. grad. Boosting	1,2	29	6	474
Brud	Log. regr. Net	1,1	80	16	1461
Gastroenteritis	Extr. grad. Boosting	0,3	16	3	1160
Sociale og plejemæssige forhold	Extr. grad. Boosting	0,3	7	1	709
Tryksår	-	-	<5	-	-
Ernæringsbetinget anæmi	-	-	<5	-	-

*Præcision ved 20% recall, **Antal opsporet er 20% af indlagte. Antal forudsagt indlagt er antal opsporet / præcision

Tabel 11. 90 dages forudsigelsesevne af modeller for forebyggelige diagnoser blandt plejehjemsbeboere i Københavns Kommune. Diagnosemodellernes forudsigelsesevne er angivet som præcision (%) ved 20% recall. Forventet antal indlagte (gennemsnit i træningssættet), opsporet af indlagte og alarmeret af modellen per 3.000 hjemmeplejemodtagere. Manglende tal angiver < 5 borgere bliver gennemsnitligt indlagt indenfor 90 dage, hvilke er maskeret jvf. Danmarks Statistiks regler om mikrodata.

Forebyggelig Diagnose	Algoritme med højeste præcision*	Præcision (%) [*]	Forventet antal per 3.000 plejehjemsbeboere indenfor 90 dage		
			Indlagte	Opsporet ^{**}	Forudsagt indlagt ^{**}
Nedre luftvejssygdomme	Extr. grad. Boosting	13,4	88	18	131
Forstoppelse	Log. regr. Net	6,2	6	1	18
Brud	Log. regr. Net	2,0	27	5	267
Blærebetændelse	Random forest	1,9	19	4	197
Dehydrering	Log. regr. Net	1,6	26	5	396
Gastroenteritis	-	-	<5	-	-
Sociale og plejemæssige forhold	-	-	<5	-	-
Tryksår	-	-	<5	-	-
Ernæringsbetinget anæmi	-	-	<5	-	-

*Præcision ved 20% recall, **Antal opsporet er 20% af indlagte. Antal forudsagt indlagt er antal opsporet / præcision

Tabel 12. 90 dages forudsigelsesevne af modeller for forebyggelige diagnoser blandt hjemmeplejemodtagere i Københavns Kommune kun med data tilgængeligt for Københavns Kommune. Diagnosemodellernes forudsigelsesevne er angivet som præcision (%) ved 20% recall. Forventet antal indlagte (gennemsnit i træningssæt), opsporet af indlagte og alarmeret af modellen per 10.000 hjemmeplejemodtagere. Manglende tal angiver < 5 borgere bliver gennemsnitligt indlagt indenfor 90 dage, hvilke er maskeret jvf. Danmarks Statistiks regler om mikrodata.

Forebyggelig Diagnose	Algoritme med højeste præcision*	Præcision (%)*	Forventet antal per 10.000 hjemmeplejemodtagere indenfor 90 dage		
			Indlagte	Opsporet**	Forudsagt indlagt**
Nedre luftvejssygdomme	Extr. grad. boosting	14,5	260	52	358
Dehydrering	Log. regr. Net	4,8	95	19	399
Blærebetændelse	Log. regr. Net	2,2	42	8	384
Brud	Log. regr. Net	1,2	80	16	1337
Forstoppelse	Log. regr. Net	0,9	29	6	680
Gastroenteritis	Extr. grad. Boosting	0,6	16	3	508
Sociale og plejemæssige forhold	Extr. grad. Boosting	0,3	7	1	728
Tryksår	-	-	<5	-	-
Ernæringsbetinget anæmi	-	-	<5	-	-

*Præcision ved 20% recall, **Antal opsporet er 20% af indlagte. Antal alarmeret er antal opsporet / præcision


Tabel 13. 90 dages forudsigelsesevne af modeller for forebyggelige diagnoser blandt plejehjemsbeboere i Københavns Kommune kun med data tilgængeligt for Københavns Kommune. Diagnosemodellernes forudsigelsesevne er angivet som præcision (%) ved 20% recall. Forventet antal indlagte (gennemsnit i træningssættet), opsporet af indlagte og alarmeret af modellen per 3.000 hjemmeplejemodtagere. Manglende tal angiver < 5 borgere bliver gennemsnitligt indlagt indenfor 90 dage, hvilke er maskeret jvf. Danmarks Statistiks regler om mikrodata.

Forebyggelig Diagnose	Algoritme med højeste præcision*	Præcision (%) [*]	Forventet antal per 3.000 plejehjemsbeboere indenfor 90 dage		
			Indlagte	Opsporet**	Forudsagt indlagt**
Nedre luftvejssygdomme	Log. regr. Net	8,9	88	18	197
Forstoppelse	Ensemble average	4,6	6	1	24
Dehydrering	Log. regr. Net	2,1	26	5	244
Blærebetændelse	Random forest	1,8	19	4	210
Brud	Log. regr. Net	1,5	27	5	369
Gastroenteritis	-	-	<5	-	-
Sociale og plejemæssige forhold	-	-	<5	-	-
Tryksår	-	-	<5	-	-
Ernæringsbetinget anæmi	-	-	<5	-	-

*Præcision ved 20% recall, **Antal opsporet er 20% af indlagte. Antal alarmeret er antal opsporet / præcision

7.3 Test sæt præcision per måned

Det er også muligt at undersøge hvordan årsmodellernes præcisions er hen over året på testsættet. Figur 15 viser præcisionen givet 20% recall, hen over året for modellen for 90 dages forudsigelses af indlæggelse med nedre luftvejssygdomme blandt hjemmeplejemodtagere. Præcisionen for de enkelte måneder ligger i intervallet 18-48%, dvs der er relativt stor variation mellem de enkelte måneder. Dog er de enkelte måneder nogenlunde symmetrisk fordelt om præcisionen for hele året, 28,6% (Tabel 10).

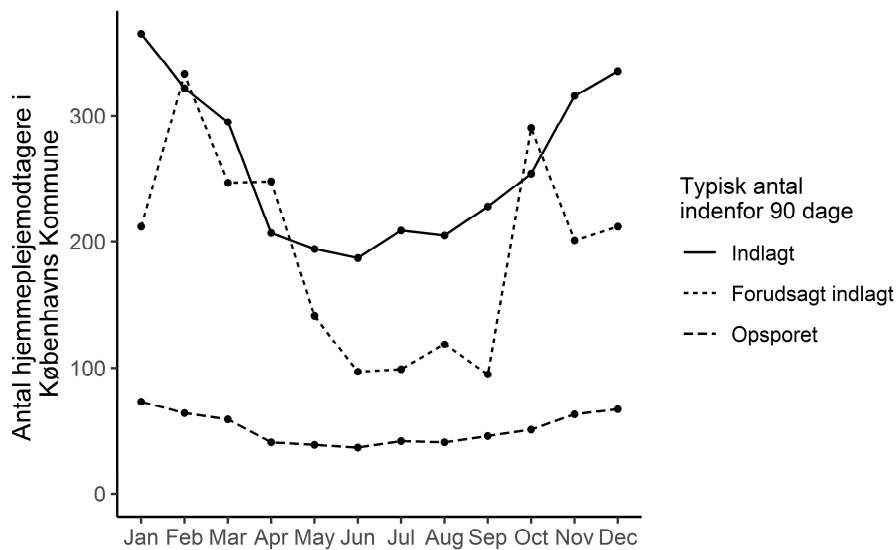


Figur 15. Præcision vs. måned på testsættet af modellen for forudsigelses af indlæggelse med nedre luftvejssygdomme blandt for hjemmeplejemodtagere.

Ud fra modellens præcision givet 20% recall angivet i Figur 15 og andel indlagt er typisk antal indlagt, forudsagt indlagt og opsporet per 10.000 hjemmeplejemodtagere estimeres (Figur 16).

Det ses at antallet af indlagte indenfor 90 dage (fuld optrukket linje i Figur 16) er størst i vintermånederne med over 300 indlagte og mindst i sommermånederne omkring 200 indlagt¹. Antal opsporet (stiplet linje i Figur 16) med modellen udvikler sig proportionalt med antal indlagte, idet antal opsporet er fastsat som 20% (=recall) af antal indlagte og ligger mellem 40 – 70 hjemmeplejemodtagere. Antallet af forudsagt indlagt af modellen (prikkede linje i Figur 16) for at finde de opsporede er givet ud fra antal opsporet / præcision. Antallet af forudsagt indlagt er omkring 250 i vintermånederne og omkring 100 i sommermånederne. For en god model er der lille forskel mellem antallet af forudsagt indlagt og antal sporet som f.eks. i september, hvor modellen forudsiger 95 til indlæggelses og 46 af disse faktisk bliver indlagt (præcision = $46/95 \cdot 100\% = 48\%$). I april er forudsigelsen dårligere hvor modellen forudsiger 240 til indlæggelses op 43 af disse faktisk bliver indlagt (præcision = $43/240 \cdot 100\% = 18\%$).

¹ Der gøres opmærksom på at modellerne er lavet på data fra 1. oktober 2017 til 1. september 2018 og således ligger data i Figur 21 fra oktober til og med december før januar i figuren.

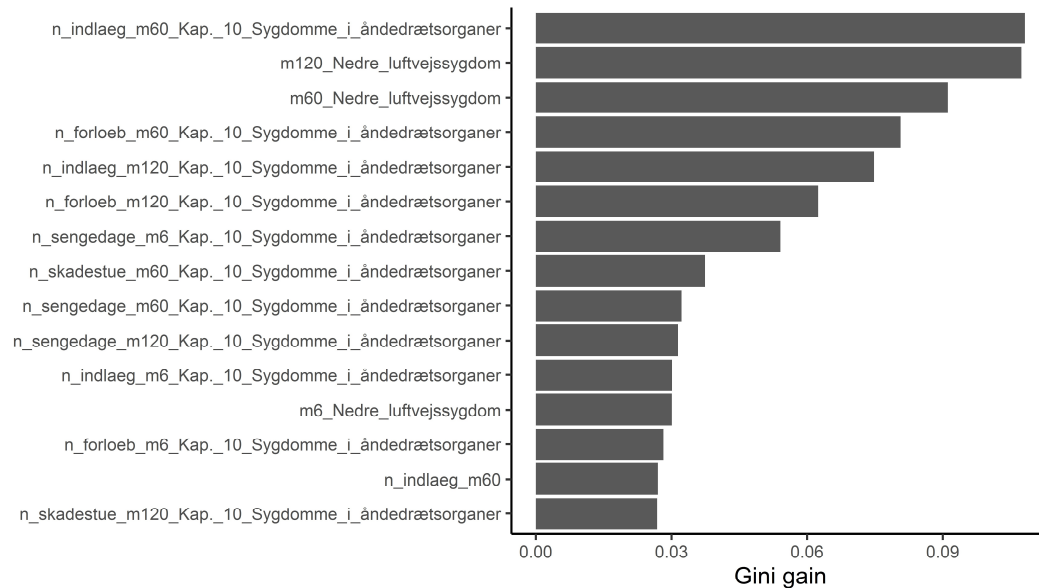


Figur 16. Antal indlagte, forudsagt indlagt og opsporet med nedre luftvejssygdom vs. måned per 10.000 hjemmeplejemodtagere med årsmodelltilgangen.

7.4 Variable med betydning for forudsigelse af indlæggelse

Det er muligt at få et indblik i hvilke variable der er vigtige for forudsigelsen af indlæggelse med de respektive diagnoser. Variablenes betydning for forudsigelsen (feature importance) bestemmes forskelligt for de tre algoritmer anvendt. Feature importance for nedre luftvejssygdom med algoritmen extreme gradient boosting er vist i Figur 17 (alt data) og Figur 18 (data tilgængeligt for Københavns Kommune).

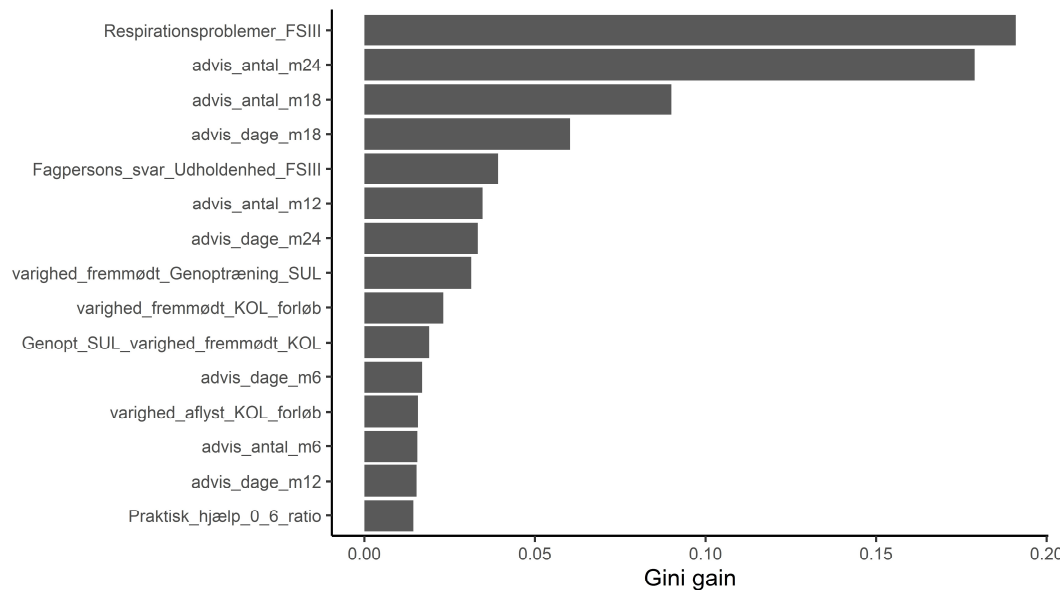
Beslutningstræer, der er grundlaget for extreme gradient boosting og random forest, dannes ved at splitte observationer mellem variable levels der maksimerer *impurity* (urenheden af klasseopdelingen). En høj *impurity* betyder at observationer i ringe grad er opdelt i responsvariablens klasser (her indlagt vs. ikke-indlagt). Ved at udregne det gennemsnitlige fald i *impurity* for hver feature i alle træer estimeres gini gain der er udtryk for variabelens vigtighed for forudsigelsen. Figur 17 viser top 15 features med betydning (gini gain) for forudsigelse af 90 dages indlæggelse med nedre luftvejssygdom blandt hjemmeplejemodtagere med alt tilgængeligt data.



Figur 17. Top 15 variable med betydning (gini gain) for forudsigelse af nedre luftvejssygdomme indenfor 90 dage blandt hjemmeplejemodtagere med extreme gradient boosting algoritmen.

Figuren viser at den mest betydningsfulde variable for forudsigelse af fremtidig (90 dage) indlæggelse med nedre luftvejssygdom er hvor mange indlæggelser med sygdomme i åndedrætsorganer en borger har haft de sidste 5 år (60 måneder, variabel: n_indlaeg_m60_Kap_10_Sygdomme_i_andedraetsorganer). Det ses at variable om tidligere indlæggelser inden sygdomme i åndedrætsorganer (data fra landspatientregistret) dominerer top 15 features. Endvidere ses at features med lang tids historik (m60_ = antal x seneste 60 måneder eller m120_ = antal x seneste 120 måneder) har større betydning for forudsigelse af indlæggelse end kort tids historik (m6_x = antal x sidste 6 måneder).

Figur 18 viser top 15 variable med betydning (gini gain) for forudsigelse af 90 dages indlæggelse med nedre luftvejssygdom blandt hjemmeplejemodtagere, men kun med data tilgængeligt for Københavns Kommune. Det betyder at data fra landspatientregisteret om tidligere indlæggelser ikke er inkluderet. I Københavns Kommune findes data om tidligere indlæggelser i en mere grovkornet version gennem adviseringer fra hospitaler om at borgeren har været indlagt samt hvor mange sengedage borgere har haft. Når landspatientregisterdata ikke er til rådighed er FSIII helbredsbedømmelsen *Respirationsproblemer* den mest betydningsfulde for forudsigelse af fremtidig indlæggelse med nedre luftvejssygdom. Dernæst er advisering om indlæggelse fra hospitaler betydningsfulde for forudsigelsen.



Figur 18. Top 15 variable med betydning (gini gain) for forudsigtelse af nedre luftvejssygdomme indenfor 90 dage blandt hjemmeplejemodtagere med extreme gradient boosting algoritmen. Modellen bag har kun haft data tilgængeligt for Københavns Kommune.

I bilag A.1 (Feature importance for diagnose modeller) kan top 15 mest betydende variable (gini gain) for de resterende extreme gradient boosting modeller for alle forebyggelige diagnoser og grupper (hjemmeplejemodtagere og plejehjemsbeboere) angivet i Tabel 10 til Tabel 13.

7.5 Konklusion

Der er udviklet 90 dages forudsigelsesmodeller for alle ni forebyggelige indlæggelsesdiagnoser for hjemmeplejemodtagere og plejehjemsbeboere. Hovedkonklusionen er at kun modellen til forudsigtelse af indlæggelse med nedre luftvejssygdom blandt hjemmeplejemodtagere vurderes at have tilstrækkelig høj forudsigelsesevne til at være praktisk brugbar. Modeller udviklet kun med data tilgængeligt fra Københavns Kommune vurderes ikke tilstrækkelige gode til praktisk anvendelse.

En opsporingsgrad (=recall) på 20% er vurderet som den øvre grænse for at sikre antallet af forudsagt indlagt ikke bliver så stort at det ikke vil være praktisk muligt for sundheds- og omsorgsforvaltningen at reagere på. Såfremt modellernes forudsigelsesevne øges kan opsporingsgraden også øges uden at antallet af alarmerede øges. En opsporingsgrad på 20% betyder at man kan forvente at 20% af de fremtidigt indlagte vil blive opsporet af modellen.

For 90 dages forudsigtelse af nedre luftvejssygdom hos hjemmeplejemodtagere blev der opnået en præcision på 28% ved en 20% recall (opsporingsgrad). Med en 90 dages incidens af indlæggelse med nedre luftvejssygdom på 2,6% betyder dette at per 10.000 hjemmeplejemodtagere forventes 52 ($=0,026 \cdot 0,2 \cdot 10.000$) fremtidig indlagte opsporet og 185 ($=52/0,28$) forudsagt indlagt for at opspore disse 52, hver gang en forudsigtelse foretages. Når kun data tilgængeligt for Københavns Kommune anvendes opnås en forudsigelsespræcision på 15% ved en opsporingsgrad på 20%. Det betyder at per 10.000 hjemmeplejemodtager forventes 52 indlagte opsporet og 358 forudsagt indlagt, hver gang forudsigelsen foretages.

Dette vurderes af forfatterne som et for højt antal borgere for sundheds- og omsorgsforvaltningen af reagere på givet antallet af opsporet fremtidigt indlagt, men fagfolk fra sundheds- og omsorgsforvaltningen må bedre kunne foretage denne vurdering.

De resterende forebyggelige indlæggelsesdiagnoser har under 5% præcision ved 20% recall (opsporingsgrad), hvilket vurderes for lavt idet antallet af forudsagt indlagte bliver for højt i forhold til antallet der opspores.

Variablebetydning (eng. feature importance) for modellen til forudsigelse af indlæggelse med nedre luftvejssygdom i hjemmeplejen viser at antallet af tidligere indlæggelser med nedre luftvejssygdom er den mest betydende variable i modellen for forudsigelse af 90 dages fremtidige indlæggelse med nedre luftvejssygdom. Endvidere er top 15 mest betydende variable, variable som alle indeholder information om tidligere indlæggelser.

8. Månedsmodeller for indlæggelsesforudsigtelse

Dette afsnit beskriver udvikling af modeller til forudsigtelse af forebyggelige indlæggelser med den såkaldte månedsmodeltilgang (se nærmere i afsnit 6.5 Håndtering af årstidsvariation) samt resultater for modellernes forudsigtelsesevne. Der laves kun forudsigtelsesmodeller for indlæggelse med diagnosen nedre luftvejssygdomme, idet årsmodellerstilgangen viste at forudsigtelsesmodeller for denne type indlæggelse er mest lovende. Der udvikles månedsmodeller separate for hjemmeplejemodtagere og plejehjemsbeboere. Endelig vises både modeller med alt tilgængeligt data anvendt og med data tilgængeligt for Københavns Kommune.

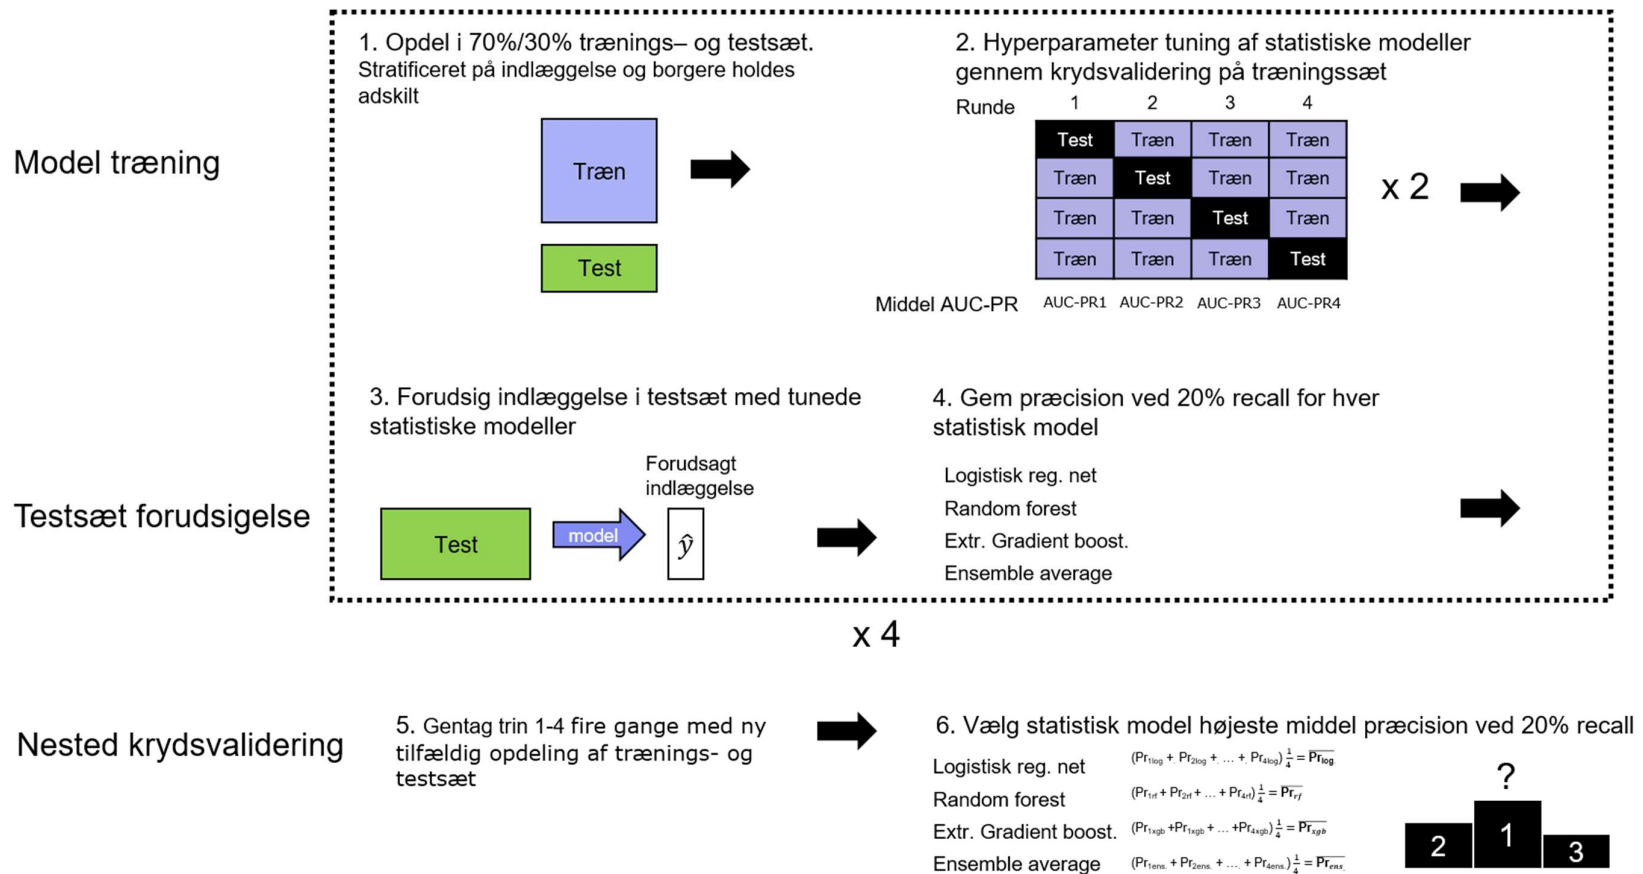
8.1 Procedure for modeludvikling

Modeludvikling med månedsmodeltilgangen (Figur 19) følger proceduren fra årsmodeltilgangen (Figur 13) med følgende forskelle:

Dataforberedelse: I månedsmodeltilgang laves én datamatrice for hvert forudsigtelsestidspunkt dvs. én datamatrice for hver måned. Forudsigtelsestidspunkterne er valgt som den første i hver måned fra 1. oktober 2017 til 1. september 2018. Hele modeludviklingsprocessen vist i Figur 19 gennemføres på hver af de 12 månedsmatricer.

Modeltræning og testsæt forudsigtelse: Der anvendes samme procedure som årsmodeltilgangen for hver månedsmatrise. Ved årsmodeltilgangen blev der i sidste trin valgt den model blandt de 4 statistiske modeller, der havde den højeste præcision, givet 20% recall. Hvis denne tilgang udføres for hver måneds fire statistiske modeller er der risiko for såkaldt model selektionsbias idet testsæt variansen her er højere.


Nested krydsvalidering: Hvert månedstestsæt er en del mindre (12 gange) end årstestsættet, hvilket betyder at testsæt variansen er højere. Testsæt varians dækker over at en models forudsigtelsesevne er forskellig i tilfældigt udvalgte testsæt. I denne rapport betyder høj test sæt varians konkret, at der – ved tilfældighed - er stor forskel i præcision (%) givet 20% recall mellem forskellige tilfældigt udvalgte test. Generelt stiger testsæt variansen med faldende antal observationer i datasættet. For at få et bedre estimat for hvilken model der vil have den bedste forudsigtelsesevne på fremtidig data udføres nested krydsvalidering (Krstajic, Buturovic, Leahy, & Thomas, 2014). I nested krydsvalidering gentages trin 2-5 i Figur 19 hvor der for hver gentagelse laves en ny tilfældig opdeling i trænings- og testsæt. I denne rapport gentages dette (ydre loop) fire gange. Således vil der for hver måned for hver statistisk model findes fire præcision-givet-20%-recall estimater. Middel af disse fire præcisionsestimater giver et mere robust estimat for præcisionen på nye data. For hver måned vælges den statistiske model med den højeste middel præcision givet 20% recall.



Figur 19. Flow diagram over udvikling af månedsmodel til forudsigelse af indlæggelse med forebyggelige diagnoser.

8.2 Resultater


Figur 20 viser middel præcision (+/- standard afvigelse) givet 20% recall vs. måned for den statistiske model med den højeste middel præcision inden for måned. I bilag 0 Figur 39 ses middel præcision vs. måned for hver af de fire statistiske modeller anvendt. April-modellen viser den mindste middel præcisionen (19%) og juli-modellen viser den højeste middel præcision (44%). Med undtagelse af april-modellen har alle modeller en præcision højere end 20% givet 20% recall, hvilket vurderes anvendeligt som alarmeringsværktøj i Københavns Kommune. +/- standard afvigelsen omkring middel præcision indikerer at der kan forventes en vis variation i præcisionen på nye data. Det ses at præcisionen er lavest i forår og efterårs modeller og højest i vinter og sommer modeller. Spørgsmålet er naturligvis om denne årstidsafhængighed af præcisionen er generelt gældende eller specifik for dette år der er anvendt til modelleringen.



Figur 20. Præcision givet 20% recall vs. måned. Punkter angiver middel præcision og barer angiver +/- standard afvigelsen af præcision mellem fire testsæt i nested krydsvalidering.


Ud fra bedste models præcision givet 20% recall angivet i Figur 20 og andel indlagt inden for 90 dage i træningsdata kan typisk antal indlagt, forudsagt indlagt og opsporet per 10.000 hjemmeplejemodtagere estimeres (Figur 21). Det ses at antallet af indlagte indenfor 90 dage (fuld optrukket linje i Figur 21) er størst i vintermånederne med over 300 indlagte og mindst i sommermånederne omkring 200 indlagt². Antal opsporet (stiplet linje i Figur 21) med modellen udvikler sig proportionalt med antal indlagte, idet antal opsporet fastsat som 20% (=recall) af antal indlagte og ligger mellem 40 – 70 hjemmeplejemodtagere. Antallet af forudsagt indlagt af modellen (prikkede linje i Figur 21) er givet ud fra antal opsporet / præcision. Eksempelvis giver den lave præcision for april-modellen (19%) anledning til et højt antal forudsagt indlagte (244) for at opspore 20% af de indlagte (46) indenfor 90 dage. Den høje præcision for juli-modellen (44%) giver anledning til at relativt lavt antal forudsagt indlagte (99) for at opspore 20% af de indlagte (44) indenfor 90 dage.

² Der gøres opmærksom på at modellerne er lavet på data fra 1. oktober 2017 til 1. september 2018 og således ligger data i Figur 21 fra oktober til og med december før januar i figuren.




Figur 21. Antal indlagte, forudsagt indlagt og opsporet med nedre luftvejssygdom vs. måned per 10.000 hjemmeplejemodtagere med månedsmodeltilgangen.

Figur 22 viser middel præcision (+/- standard afvigelse) givet 20% recall vs. måned for den bedste model hvor kun data til rådighed for Københavns Kommune er anvendt. Det ses at præcisionen er en del mindre end når alt tilgængeligt data (inklusive tidligere indlæggelser) anvendes.



Figur 22. Præcision givet 20% recall vs. måned for forudsigelsesmodeller hvor der kun er anvendt data tilgængeligt fra Københavns Kommune. Punkter angiver middel præcision og barer angiver +/- standard afvigelsen af præcision mellem fire testsæt i nested krydsvalidering.

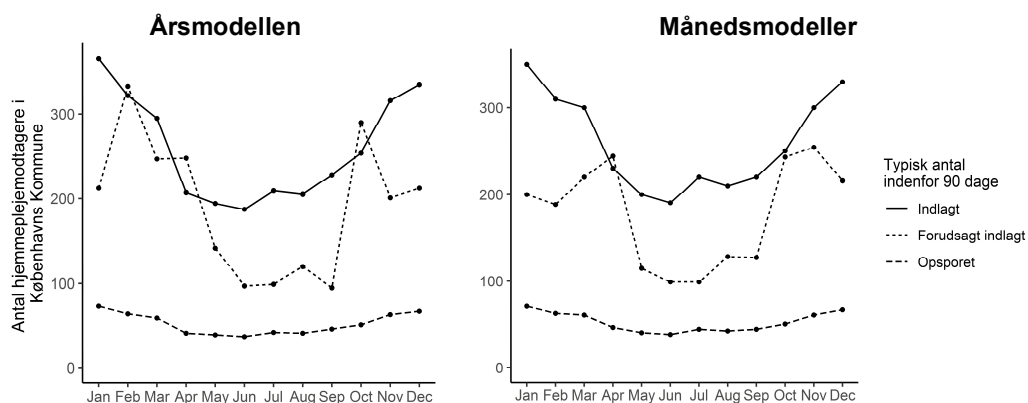


Figur 23. Antal indlagte, forudsagt indlagt og opsporet med nedre luftvejssygdom vs. måned per 10.000 hjemmeplejemodtagere med månedsmodeltilgangen når kun data tilgængeligt for Københavns Kommune anvendes i modeludviklingen.

Ud fra præcisionen angivet i Figur 22 og andel indlagt inden for 90 dage i træningsdata kan typisk antal indlagt, forudsagt indlagt og opsporet per 10.000 hjemmeplejemodtagere estimeres (Bilag A). Det ses at antal forudsagt indlagt ved mange måneder er mere en dobbelt så højt som modellen hvor også landspatientregisterdata er anvendt.

8.3 Sammenligning mellem årsmodellen og månedsmodellen

Er månedsmodeller bedre end årsmodeller? Hvordan evalueres dette? Hvis man kigger på antallet af forudsagt indlagt er i de fleste måneder højere for årsmodellen end månedsmodellerne. Det vil sige at årsmodellen er dårligere i den henseende. Dog kan årsmodellens forudsigelse på nye års data tænkes at være mere robust end månedsmodellerne, idet flere data er anvendt end de enkelte månedsmodeller. Dette vil kunne afgøres, hvis flere års data senere bliver tilgængeligt til test senere.



Figur 24. Sammenligning af forudsigelse med årsmodellen og månedsmodeller for 90 dages forudsigelse af indlæggelse med nedre luftvejssygdom for hjemmeplejemodtagere.

I Tabel 14 er årsmodellen og månedsmodellerne vurderet mht. forudsigelsespræcision, vurderet robusthed på fremtidige data og kompleksitet ved implementering for modellen til forudsigelse af nedre luftvejssygdom blandt hjemmeplejemodtagere. Årsmodellen viser mindre præcision end månedsmodellerne, men det tænkes at robustheden på fremtidige data er større med årsmodellen. Kompleksitet ved implementering af månedsmodellerne af en del højere end årsmodellen, idet forskellige typer statistiske modeller er anvendt i de 12 månedsmodeller.

Tabel 14. Sammenligning af modeller til forudsigelse af 90 dages indlæggelse med nedre luftvejssygdom blandt hjemmeplejemodtagere.

	Årsmodel	Månedsmodeller
Forudsigelsespræcision	😊	😊😊
Vurderet robusthed på fremtidig data	😊😊	😊
Kompleksitet ved implementering	😊	😞

8.4 Konklusion

Der er udviklet 12 månedsmødeller (januar, februar, ... december) til forudsigelse af 90 dages indlæggelse med nedre luftvejssygdomme. Når forudsigelse skal foretages i fremtiden skal den model der ligger tættest på forudsigelsestidpunktet vælges. Hvis der f.eks. den 25. januar ønskes en forudsigelse af hvilke københavnske hjemmeplejemodtagere det vil blive indlagt med nedre luftvejssygdom næste 90 dage vil februar modellen anvendes, idet 1. februar er tættere på 25. januar end 1. januar.

Månedsmødellerne viser højere præcision end årsmødellen, men test på nye års data mangler, hvilket ville afgøre den endelige forudsigelsespræcision

9. Konklusion

Hovedspørgsmålet i denne rapport har været, hvorvidt det er muligt at udvikle en statistisk model, der ud fra en ældre borgers data kan forudsige om borgeren vil blive indlagt med en forebyggelig diagnose indenfor 90 dage.

Målgruppen er i denne rapport fokuseret til borgere på 65 år eller ældre i hjemmeplejen eller på plejehjem. I Københavns Kommune udgør denne gruppe 20% af borgerne på 65 år eller ældre, men står for over halvdelen af de forebyggelige indlæggelser. De forebyggelige indlæggelser kategoriseres i ni typer, hvor nedre luftvejssygdomme som den hyppigste indlæggelsestype udgør over halvdelen af det totale antal forebyggelige indlæggelser.

Der er uddraget over 700 forklarende variable om borgerne der afspejler

- borgernes uddannelsesniveau og demografi
- hvilke kommunale omsorgsydelser borgerne har modtaget
- sundhedsvurderinger og -målinger foretaget på borgere
- borgerens indlæggelseshistorik

Der er udviklet 90 dages forudsigelsesmodeller for alle ni forebyggelige indlæggelsesdiagnoser for hjemmeplejemodtagere og plejehjemsboere. Hovedkonklusionen er dog at kun modellen til forudsigelse af indlæggelse med nedre luftvejssygdom blandt hjemmeplejemodtagere vurderes at have tilstrækkelig høj forudsigelsesevne til at være praktisk brugbar. Modeller udviklet kun med data tilgængeligt fra Københavns Kommune vurderes ikke tilstrækkelige gode til praktisk anvendelse.

De 15 mest betydningsfulde forklarende variable i modellen vedr. nedre luftvejssygdomme havde at gøre med borgerens indlæggelseshistorik. Disse forklarende variable kommer fra landspatientregisteret, som på nuværende tidspunkt ikke er tilgængeligt for Københavns Kommune. Den begrænsning gør at modellen ikke implementeres og anvendes som forudsigelsværktøj i kommunen.

10. Anbefalet fremtidigt arbejde

Anvendelse af lægemiddeldatabasen forventes at give mere præcise forudsigelser

Indarbejdelse af borgernes medicinkøb forventes at kunne øge præcisionen af modellernes indlæggelsesforudsigelse og vil derfor være relevant at arbejde videre med.

Den danske lægemiddeldatabase indeholder detaljeret information om receptpligtig medicin indløst af danskere herunder købsdato (Pottegård, et al., 2017). Det såkaldte Anatomical Therapeutic Chemical (ATC) klassifikationskodesystem inddeler hierarkisk lægemidler i farmaceutisk funktionelle undergrupper, som f.eks. A10BJ06 (semaglutide) med level 2 gruppeinddelingen *A10* (drugs used in diabetes) og level 3 gruppeinddelingen *A10B* (glucose lowering drugs, excluding insuline).

I et studie der har udviklet en prædiktionsmodel for fremtidigt behov for hjemmepleje blev medicinkøb, sammen med demografi og tidligere indlæggelser fundet betydningsfulde for modellens prædiktionssevnen (Wright, Kusumastuti, Mortensen, Westendorp, & Gerds, 2021). En tidligere dansk rapport har dokumenteret at ressourcetrækket i det regionale sundhedsvæsen er markant højere blandt personer med kronisk sygdom og ældre medicinske patienter (Kommunernes Landsforening, Finansministeret, Økonomi- og Indenrigsministeriet, Ministeriet for Sundhed og Forebyggelse, 2013). Idet kronisk syge ofte blive medicineret for deres sygdom kunne man forvente at information om deres medicinkøb vil være en indikator for deres risiko for fremtid indlæggelse.

Prædiktionsmodeller med bredere outcomes forventes at give screeningsmodeller

Mere bredt definerede outcomes som 90 dage risiko for

- akut indlæggelse af enhver slags eller
- forebyggelig indlæggelse af enhver type

kunne give mere præcise forudsigelser idet incidensen samlet set, vil være langt højere og dermed vil kunne give et bedre grundlag for modeludvikling. Derfor vil det være relevant at arbejde videre med.

Denne rapport dokumenterer udvikling af separate prædiktionsmodeller af de enkelte forebyggelige indlæggelsestyper f.eks. en model for indlæggelse nedre luftvejssygdom, en model for indlæggelse med dehydrering, etc. Prædiktions af indlæggelse med en specifik type forebyggelig indlæggelse har været vurderet mere brugbar end prædiktions af en bredere outcome definition f.eks. akut indlæggelse af enhver slags, idet en specifik outcome prædiktions, gør det lettere at videre hvilken intervention der skal foretages. Dog kan brede outcomes stadig være relevante som screeningsværktøj til at indsnævre gruppen af borgere, som man kan lave opfølgende undersøgelser på.

Mere detaljerede kommunale indlæggelsesdata forventes at give mere præcise modeller

I denne rapport har prædiktorer med antallet af indlæggelser de seneste 6 måneder, 5 år og 10 år indenfor forskellige ICD-10 kapitler været de mest betydende for prædiktionsmodeller af 90 dages risiko for indlæggelse. Disse data stammer fra landspatientregisteret, der ikke er

tilgængeligt for Københavns Kommune i realtid og heller ikke anses at blive det indenfor nær fremtid. Implementering og løbende træning af prædiktionsmodeller kræver adgang til data i realtid, hvorfor disse prædiktorer for nuværende reelt ikke kan anvendes. Data om indlæggelser fra Københavns Kommune stammer for nuværende fra indlæggelses- og udskrivesadviser, som alene giver information om indlæggelses- og udskrivelsestidspunkt samt indlæggelses- og udskrivelsehospital og-afdeling, men f.eks. ikke hvilke diagnoser som borgeren har været indlagt med. Københavns Kommune arbejder på at få adgang til og bearbejdet mere detaljerede indlæggelsesdata herunder om aktionsdiagnoser fra udskrivesrapporterne, som kommunen modtager efter en borgers indlæggelse.

Temporal validering af prædiktionsmodeller

TRIPOD guidelines, der handler om transparent rapportering af prædiktionsmodeller indenfor sundhedsvidenskab, anbefaler at udviklede modeller valideres på data der er opsamlet på et senere tidspunkt end det data der er blevet brugt til at udvikle modellen (temporal validering). I det nærende projekt betyder det specifikt at data fra landspatientregisteret fra 2019 bliver tilgængeligt, hvilket det ikke er i skrivende stund. Det vil dog relevant at teste og validere modellernes forudsigelses præcision på 2019 data.

Cost-benefit analyse – kan det betale sig?

Motivationen for at forudsige borgeres 90 dages risiko for indlæggelse er at kunne koncentrere forebyggelsesressource, der hvor de gør mest gavn og dermed spare udgiften til indlæggelse og højne borgernes livskvalitet ved at forebygge sygdom.

Prædiktionsmodeller for indlæggelse vil aldrig kunne forudsige alle indlæggelser helt præcist, men vil kunne inddele borgere i x antal (f.eks. 10) risikogrupper, hvor man i den højeste risikogruppe kan forvente en større andel faktisk indlagte, end i den næsthøjeste, etc. Fordi selv den højest forudsagte risikogruppe vil indeholde borgere, der ikke bliver indlagt (falsk positiv), vil der hvis der indsættes forebyggende tiltag for risikogruppen være borgere, hvor forebyggelsen er spildt.

Det kunne være relevant at påbegynde en cost-benefit analyse, hvor man sammenholder udgifterne til indlæggelse med udgifterne for forebyggende tiltag. Udgiften for selv et dyrt forebyggende tiltag af en enkelt person vil ofte være lavere end udgiften til indlæggelse af denne person. Men hvad hvis der skal laves forebyggende tiltag for tre personer for at undgå én persons indlæggelse. Sådanne spørgsmål kunne være relevante at undersøge nærmere.

11. Referencer


- Artetxe, A., Beristain, A., & Graña, M. (2018). Predictive models for hospital readmission risk: A systematic review of methods. *Computer Methods and Programs in Biomedicine*, 164, 49–64.
- Chang, Y.-C., Chang, K.-H., & Wu, G.-J. (2018). Application of eXtreme gradient boosting trees in the construction of credit risk assessment models for financial institutions. *Applied Soft Computing Journal*, 73, 914–920.
- Chen, X., Huang, L., Xie, D., & Zhao, Q. (2018). EGBMMDA: Extreme Gradient Boosting Machine for MiRNA-Disease Association prediction. *Cell Death and Disease*, 9(3).
- Danish Ministry of Domestic and Economic Affairs. (2018). *Preventive Hospital Admissions in Home Care*. <https://simb.dk/media/20539/hovedrapport-forebyggelige-indlaeggelser-blandt-hjemmeplejemodtagere.pdf>.
- Danish National Association of Municipalities, Danish Regions, Danish Ministry of Finance, Danish Ministry of Domestic and Economic Affairs and Danish Ministry of Health and Prevention. (2013). *Effective Municipal Prevention*. Hentet fra https://sum.dk/Aktuelt/Publikationer/~media/Filer%20-%20Publikationer_i_pdf/2013/Effektiv-kommunal-forebyggelse/Effektiv-kommunal-forebyggelse.ashx
- Danmarks Statistik. (29. 7 2020). *Danmarks Statistisk*. Hentet fra Befolkningspyramide: <http://extranet.dst.dk/pyramide/pyramide.htm>
- Fournaise, A. E.-R. (2017). Increasing primary health-care services are associated with acute short-term hospitalization of Danes aged 70 years and older. *European Geriatric Medicine* 8, 435–439.
- Hastie, T. H. (2001). *The elements of statistical learning: Data mining, inference, and prediction*. New York: Springer.
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). *Introduction to Statistical Learning: with Application in R*. New York: Springer.
- Kansagara, D., Englander, H., Salanitro, A., Kagen, D., Theobald, C., Freeman, M., & Kripalani, S. (2011). Risk Prediction Models for Hospital Readmission: A Systematic Review. *JAMA*, 306 (15), 1688–1698.
- Kommunernes Landsforening, Finansministeret, Økonomi- og Indenrigsministeriet, Ministeriet for Sundhed og Forebyggelse. (2013). *Effektiv kommunal forebyggelse - med fokus på forebyggelse af indlæggelser og genindlæggelser*. Hentet fra https://sum.dk/Aktuelt/Publikationer/~media/Filer%20-%20Publikationer_i_pdf/2013/Effektiv-kommunal-forebyggelse/Effektiv-kommunal-forebyggelse.ashx
- Krstajic, D., Buturovic, J., Leahy, D. E., & Thomas, S. (2014). Cross-validation pitfalls when selecting and assessing regression and classification models. *Journal of Cheminformatics*.
- Norquist, M. (29. 6 2020). Sundhedsfaglig konsulent. (C. B. Lyndgaard, Interviewer)
- Pottegård, A., Schmidt, S. A., Wallach-Kildemoes, H., Sørensen, H. T., Hallas, J., & Schmidt, M. (2017). Data Resource Profile: The Danish National Prescription Registry. *International Journal of Epidemiology*, 798–798f.
- Probst, P., Wright, M., & Boulesteix, A. L. (2018). Hyperparameters and Tuning Strategies for Random Forest. *Advanced Review*, 1-15.

- Saito, T., & Rehmsmeier, M. (2015). The Precision-Recall Plot is More Informative than ROC plot When Evaluating Binary Classifiers on Imbalanced Datasets. *PLoS ONE*(10).
- Saito, T., & Rehmsmeier, M. (u.d.). The Precision-Recall Plot Is More Informative than the ROC Plot When Evaluating Binary Classifiers on Imbalanced Datasets.
- Shah, R. D. (2016). Modelling Interactions in High-dimensional Data with Backtracking. *Journal of Machine Learning Research* .
- Statistic Denmark. (2020). *Statistic Denmark*. Hentet 6. April 2020 fra <https://www.dst.dk/>
- Sundheds og Omsorgsforvaltning, Københavns kommunes. (2018). *OM FSIII – Tilstande og generelle oplysninger*. København. Hentet fra https://digital-omsorg.kk.dk/sites/digital-omsorg.kk.dk/files/uploaded-files/om-fsiii_tilstande_og_generelle_oplysninger.pdf
- Sundhedsdatastyrelsen. (2020). er en klassifikation af sygdomme og andre helbredsrelaterede tilstande. Hentet fra http://www.medinfo.dk/sks/brows.php?s_nod=6186
- Sundhedsstyrelsen. (2017). *Tidlig opsporing af forringet helbredstilstand og nedsat funktionsevne hos ældre mennesker*. Hentet fra <https://www.sst.dk/-/media/Udgivelser/2017/Tidlig-opsporing-af-forringet-helbredstilstand-og-nedsat-funktionsevne-hos-aeldre-mennesker.ashx?la=da&hash=EC4A2AD6BA14C83565EEFB546B268CAE396D41BF>
- Wang, F., & Ross, C. L. (2018). Machine Learning Travel Mode Choices: Comparing the Performance of an Extreme Gradient Boosting Model with a Multinomial Logit Model. *Transportation Research Records*, 2672(47), 35-45.
- Wright, M. N., Kusumastuti, S., Mortensen, L. H., Westendorp, R. G., & Gerds, T. A. (2021). Personalised need of care in an ageing society: The making of a prediction tool based on register data. *Journal of the Royal Statistical Society Series A (Statistics in Society)*, 1–21.

Bilag A

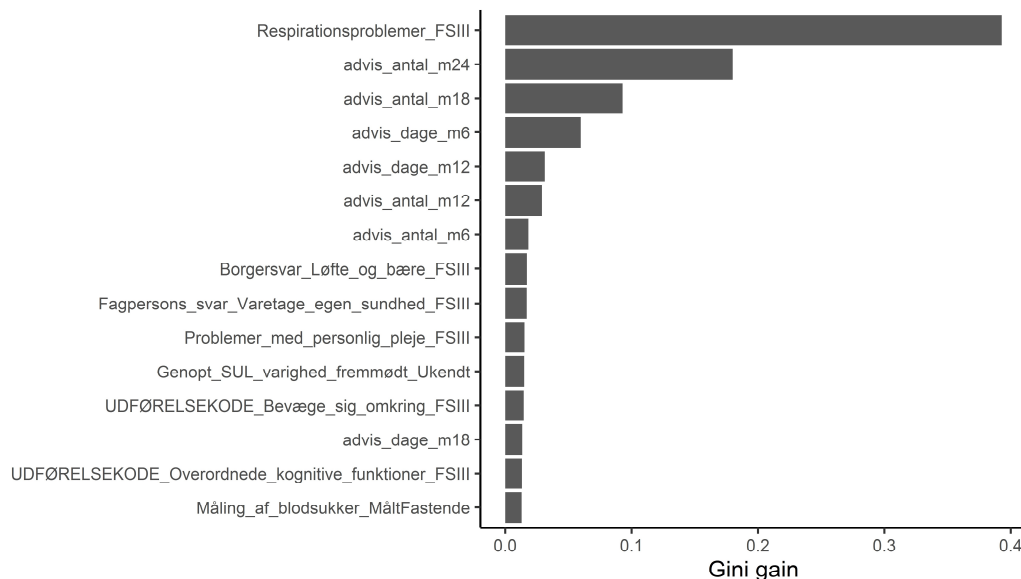
A.1. Feature importance for diagnose modeller

Nedre luftvejssygdom, plejehjembeboere



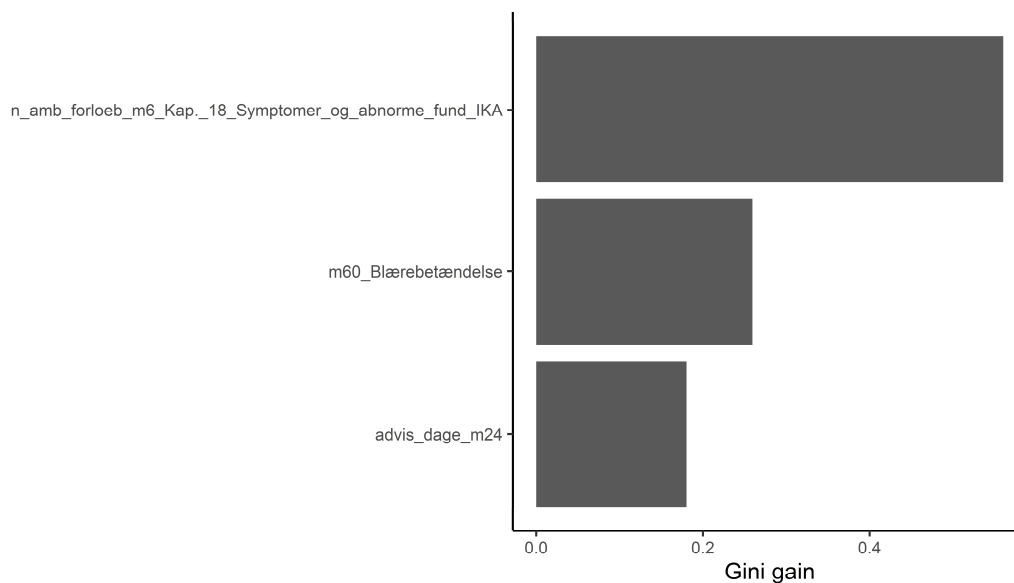
Figur 25. Top 15 variable med betydning (gini gain) for forudsigelse af indlæggelse med nedre luftvejssygdom indenfor 90 dage blandt **plejehjemsbeboere** med extreme gradient boosting algoritmen.

Nedre luftvejssygdom, plejehjembeboere, data tilgængeligt for Københavns Kommune



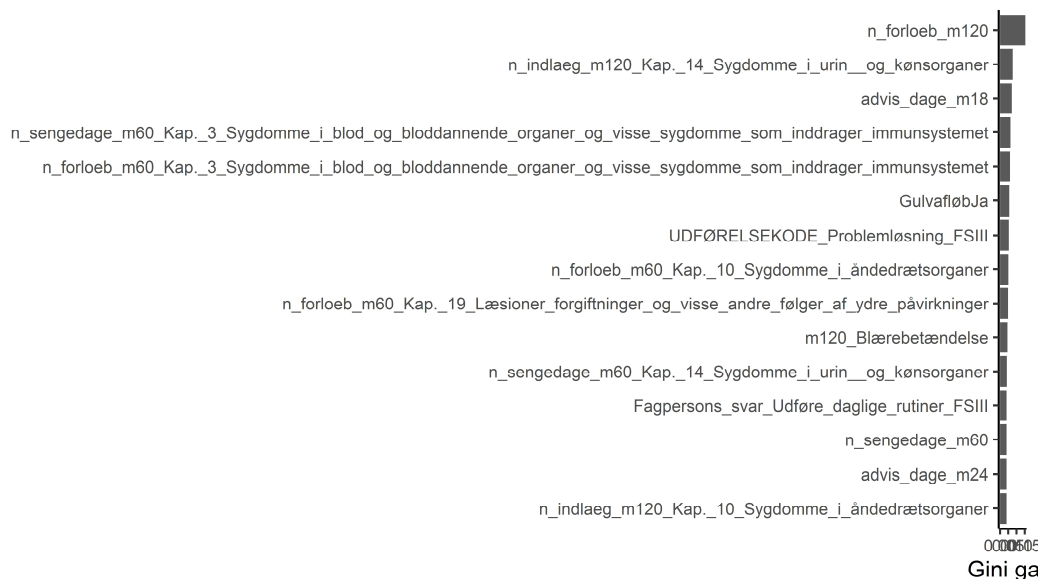
Figur 26. Top 15 variable med betydning (gini gain) for forudsigelse af indlæggelse med nedre luftvejssygdom indenfor 90 dage blandt **plejehjemsbeboere** med extreme gradient boosting algoritmen. Modellen har kun haft data tilgængeligt for **Københavns Kommune**.

Blærebetændelse, hjemmeplejemodtagere




Figur 27. Variable med betydning (gini gain) for forudsigelse af indlæggelse med blærebetændelse indenfor 90 dage blandt **hjemmeplejemodtagere** med extreme gradient boosting algoritmen.

Blærebetændelse, plejhjemsbeboere




Figur 28. Top 15 variable med betydning (gini gain) for forudsigelse af indlæggelse med blærebetændelse indenfor 90 dage blandt **plejhjemsbeboere** med extreme gradient boosting algoritmen.

Blærebetændelse, hjemmeplejemodtagere, data tilgængeligt for Københavns Kommune



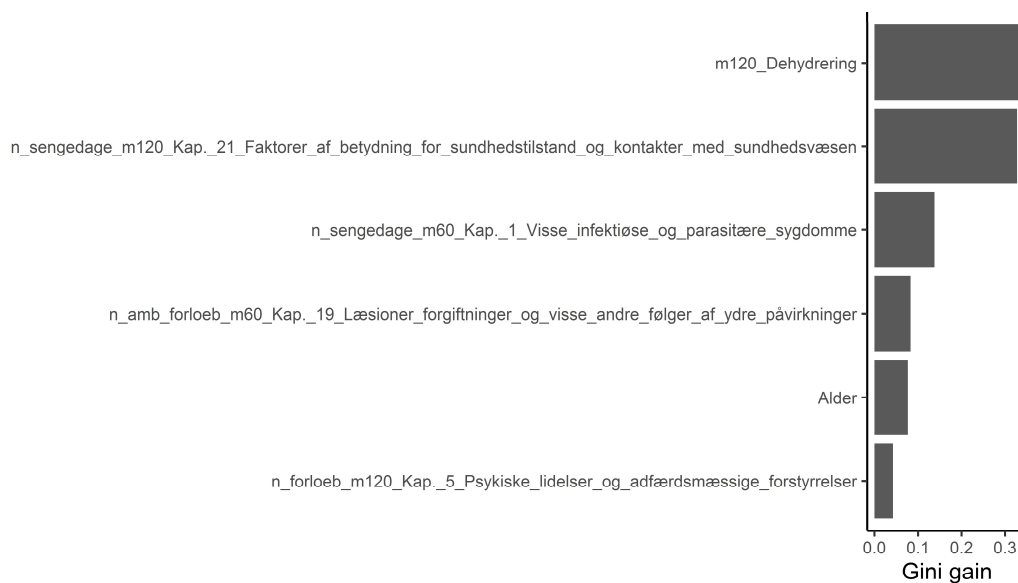
Figur 29. Top 15 variable med betydning (gini gain) for forudsigelse af indlæggelse med blærebetændelse indenfor 90 dage blandt **hjemmeplejemodtagere** med extreme gradient boosting algoritmen. Modellen har kun haft data tilgængeligt for **Københavns Kommune**.

Blærebetændelse, plejehjemsbeboere, data tilgængeligt for Københavns Kommune



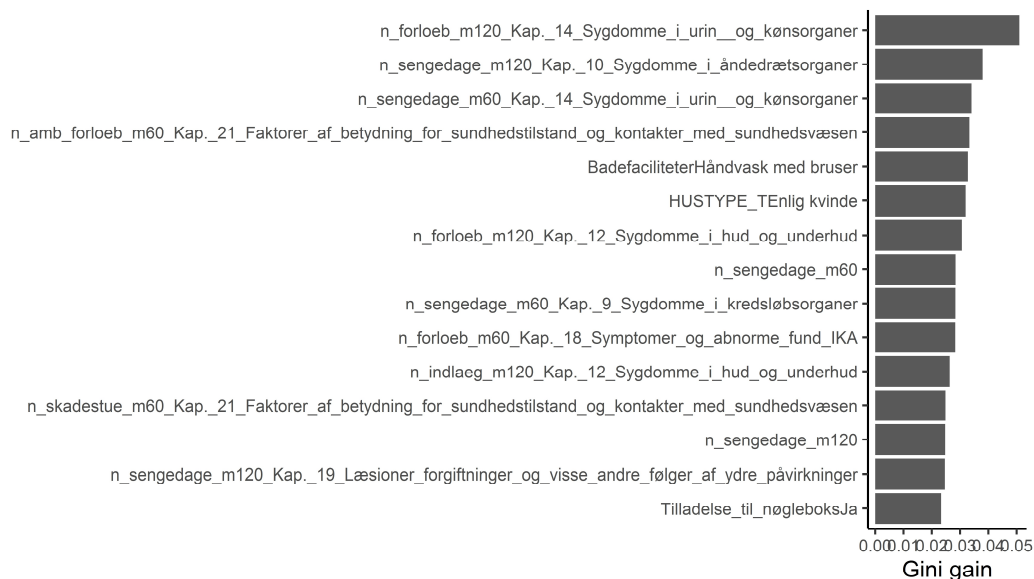
Figur 30. Top 15 variable med betydning (gini gain) for forudsigelse af indlæggelse med blærebetændelse indenfor 90 dage blandt **plejehjemsbeboere** med extreme gradient boosting algoritmen. Modellen har kun haft data tilgængeligt for **Københavns Kommune**.

Brud, hjemmeplejemodtagere




Figur 31. Variable med mest betydning (gini gain) for forudsigelse af indlæggelse med brud indenfor 90 dage blandt **hjemmeplejemodtagere** med extreme gradient boosting algoritmen.

Brud, plejehjemsbeboere




Figur 32. Variable med mest betydning (gini gain) for forudsigelse af indlæggelse med brud indenfor 90 dage blandt **plejehjemsbeboere** med extreme gradient boosting algoritmen.

Brud, hjemmeplejemodtagere, data tilgængeligt for Københavns Kommune



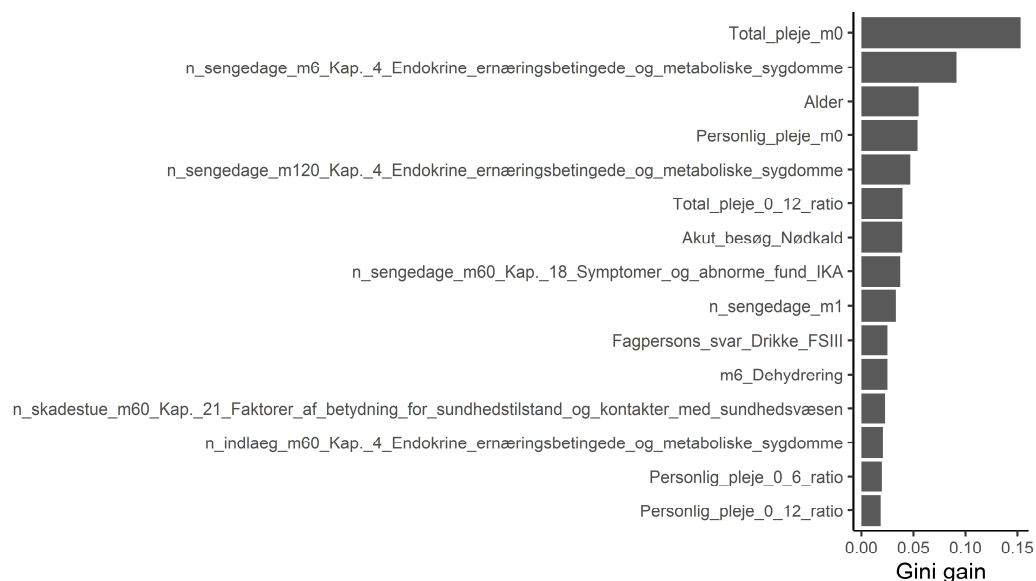
Figur 33. Variable med mest betydning (gini gain) for forudsigelse af indlæggelse med brud indenfor 90 dage blandt **hjemmeplejemodtagere** med extreme gradient boosting algoritmen. Modellen har kun haft data tilgængeligt for **Københavns Kommune**.

Brud, plejehjemsbeboere, data tilgængeligt for Københavns Kommune



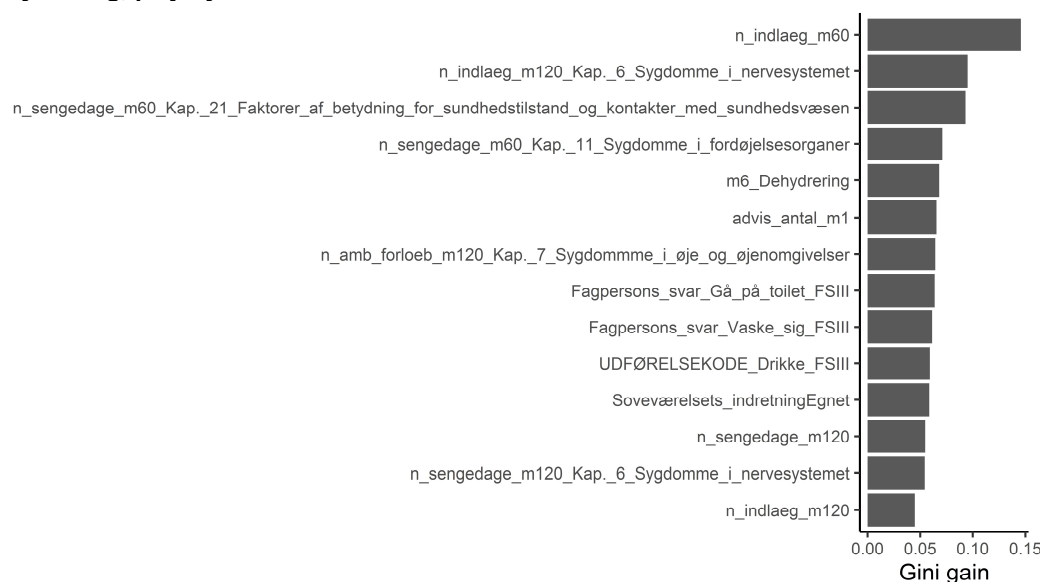
Figur 34. Variable med mest betydning (gini gain) for forudsigelse af indlæggelse med brud indenfor 90 dage blandt **plejehjemsbeboere** med extreme gradient boosting algoritmen. Modellen har kun haft data tilgængeligt for **Københavns Kommune**.

Dehydrering, hjemmeplejemodtagere



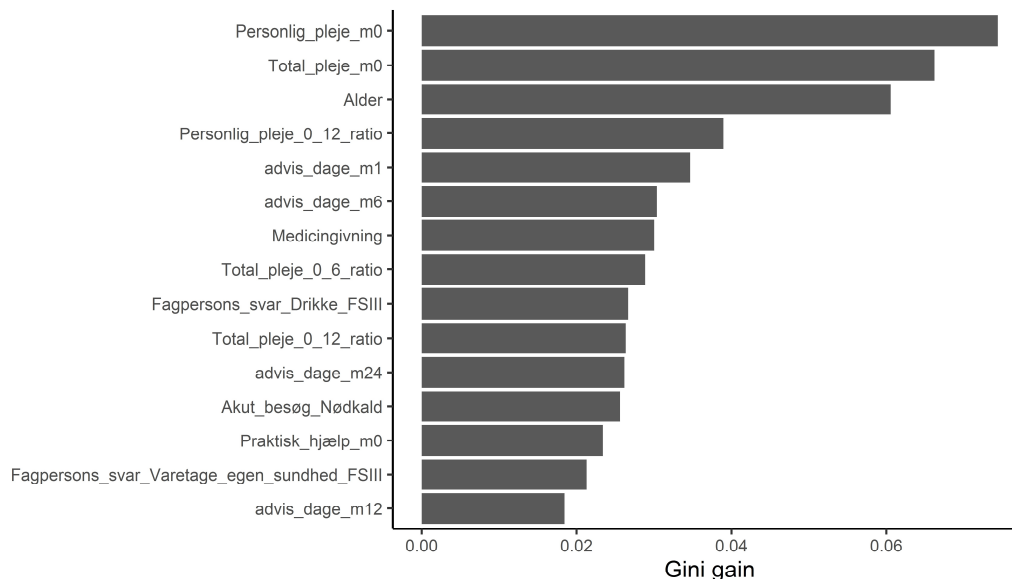
Figur 35. Variable med mest betydning (gini gain) for forudsigelse af indlæggelse med dehydrering indenfor 90 dage blandt **hjemmeplejemodtagere** med extreme gradient boosting algoritmen.

Dehydrering, plejehjemsbeboere




Figur 36. Variable med mest betydning (gini gain) for forudsigelse af indlæggelse med dehydrering indenfor 90 dage blandt **plejehjemsbeboere** med extreme gradient boosting algoritmen.

Dehydrering, hjemmeplejemodtagere, data tilgængeligt for Københavns Kommune




Figur 37. Variable med mest betydning (gini gain) for forudsigelse af indlæggelse med dehydrering indenfor 90 dage blandt **hjemmeplejemodtagere** med extreme gradient boosting algoritmen. Modellen har kun haft data tilgængeligt for **Københavns Kommune**.

Dehydrering, plejehjemsbeboere, data tilgængeligt for Københavns Kommune




Figur 38. Variable med mest betydning (gini gain) for forudsigelse af indlæggelse med dehydrering indenfor 90 dage blandt **plejehjemsbeboere** med extreme gradient boosting algoritmen. Modellen har kun haft data tilgængeligt for **Københavns Kommune**.

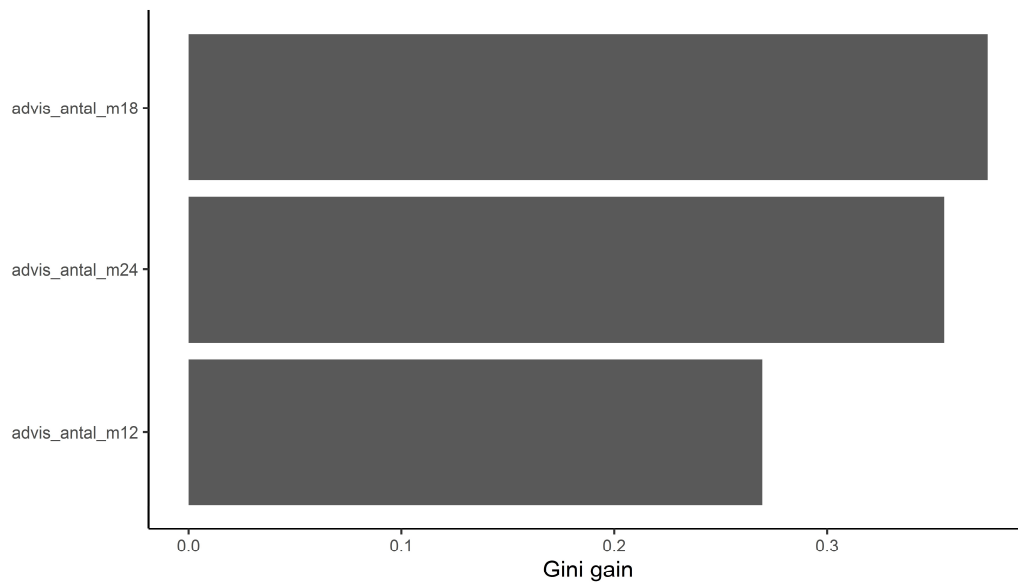
Forstoppelse, hjemmeplejemodtagere




Forstoppelse, plejehjemsbeboere




Forstoppelse, hjemmeplejemodtagere, data tilgængeligt for Københavns Kommune




Forstoppelse, plejehjemsbeboere, data tilgængeligt for Københavns Kommune




Gastroenteritis, hjemmeplejemodtagere



Gastroenteritis, plejhjemsbeboere



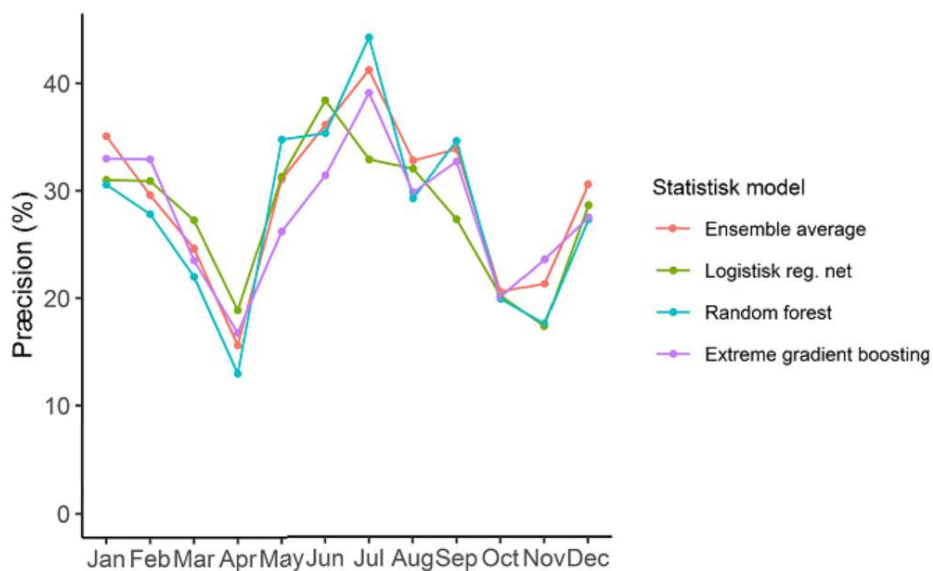
Gastroenteritis, hjemmeplejemodtagere, data tilgængeligt for Københavns Kommune



Gastroenteritis, plejehjemsbeboere, data tilgængeligt for Københavns Kommune

Ingen model kunne dannes

A.2. Månedsmodeller



Figur 39. Præcision givet 20% recall vs. måned for fire statistiske forudsigelsesmodeller for 90 dages indlæggelse med nedre luftvejssygdomme blandt hjemmeplejemedtagere. Punkter angiver middel præcision mellem fire testsæt i nested krydsvalidering.



Figur 40. Præcision givet 20% recall vs. måned for fire statistiske forudsigelsesmodeller for 90 dages indlæggelse med nedre luftvejssygdomme blandt hjemmeplejemedtagere kun med data tilgængeligt for Københavns Kommune. Punkter angiver middel præcision mellem fire testsæt i nested krydsvalidering