

Prediktiva modeller för SRS piloten; 2.2

(Delrapport Stöd för rätt sjukskrivning, gällande 2020)

Kristina Alexanderson

Gino Almondo

Innehållsförteckning

Sammanfattning	3
Förord	4
Förkortningar.....	5
Bakgrund	6
Syfte	6
Material och metod.....	6
Registerdata.....	7
Från Försäkringskassan	8
Utfallsvariabel	9
Urvalskriterier	9
Metoder för utvärdering av prediktionsmodeller	11
AIC, LogLikelihood och Brier Score	11
Goodness-of-fit.....	11
Kalibrering	11
Informativitet.....	11
Analys i Del I.....	13
Variabler i Del I.....	13
Analys i Del II.....	14
Variabler i Del II	15
Resultat.....	16
Del I.....	16
Del II	18
Stratifiering.....	18
Val av sex prediktorer	18
Utvärderingar av slutgiltiga modeller	18
Prognosvariabler, frågor och svar för användning av allmänläkare.....	20
Slutkommentar	21
Referenser, urval	23
Bilaga 1: Del I – Goodness-of-fit diagram.....	25
Bilaga 2: Del I – Kalibrering vid 90 dagar.....	27
Bilaga 3: Del II – Goodness-of-fit diagram	29
Bilaga 4: Del II – Kalibrering vid 90 dagar.....	31

Sammanfattning

I denna delrapport avrapporteras ett delprojekt från Karolinska Institutet, gjort inom ramen för det övergripande projekt som kallas Stöd för rätt sjukskrivning (SRS). Syftet med delprojektet har varit att uppdatera tidigare framtagna prediktiva modeller (SRS 2.1) för att bättre kunna identifiera vilka sjukskrivningsfall i vanliga sjukskrivningsdiagnoser som riskerar att bli långa, för att ta fram användbara modeller för prediktion av om huruvida ett sjukskrivningsfall som pågått 15 dagar riskerar att bli längre än 90 dagar.

De nya här framtagna modellerna benämns SRS 2.2.

Utgångsmaterialet i detta delprojekt var samtliga drygt 1,2 miljoner nya sjukskrivningsfall i Sverige som påbörjades under perioden från och med 1/1 2014 till och med 30/6 2016 (dvs under 2,5 år) och som blev minst 15 dagar långa. Samtliga sådana sjukskrivningsfall i var och en av de för projektet 23 utvalda sjukskrivningsdiagnoserna analyserades var för sig i projektets olika delar. Först togs nya prediktiva modeller fram, baserat på de 14 variabler som i tidigare projekt (SRS 1.0) visat sig ha störst prediktiv förmåga. Därefter togs nya prediktiva modeller fram för 20 av de utvalda diagnoserna, med ytterligare variabler från primärvård och sekundärvård. I analyserna togs de sex variabler som hade högst prediktivt värde fram för var och en av de utvalda diagnoserna, utöver vissa variabler som enligt SRS ledningen tas med i samtliga modeller (kön, ålder, samt information om diagnoskoder på subkategorinivå). Modellerna har utvärderats på flera sätt, såsom genom framtagande av AIC och Brier Score värden för modellerna, modellernas Goodness-of-fit och kalibrering respektive modellernas informativitet.

De olika modellernas prediktiva styrka befanns överlag vara god. Resultaten, i form av modeller att användas samt en sammanställning av information som ska läggas in i SRS:s modeller har levererades till SRS-projektets ledning sommaren 2020, för fortsatt pilottestning i primärvård.

Förord

Detta delprojekt utgår från det arbete som gjorts av Karolinska Institutet i tidigare projekt inom ramen för SRS-projektet, avseende prediktion av fortsatt sjukskrivning bland personer som har påbörjat ett sjukskrivningsfall ¹⁻⁴. I denna rapport rapporteras två delarna av ett delprojekt som redovisades våren 2020 (Del I och II).

Projektet, som är tvärvetenskapligt, har genomförts i samarbete med forskare och statistiker vid Avdelningen för försäkringsmedicin, Institutionen för klinisk neurovetenskap (CNS) samt vid Enheten för biostatistik vid Institutet för miljömedicin (IMM), dvs två institutioner inom Karolinska Institutet. Framför allt har följande personer vid Karolinska Institutet arbetat med projektet (i bokstavsordning):

- Kristina Alexanderson, professor i socialförsäkring, med dr, Avdelningen för försäkringsmedicin, Institutionen för klinisk neurovetenskap (CNS) (projektledare; kristina.alexanderson@ki.se)
- Gino Almondo, statistiker, Avdelningen för försäkringsmedicin (CNS)
- Matteo Bottai, professor i biostatistik, PhD in biostatistics, Enheten för biostatistik, Institutet för miljömedicin (IMM)
- Paolo Frumento, forskarassistent, PhD in statistics, Enheten för biostatistik (IMM)
- Pontus Josefsson, statistiker, Avdelningen för försäkringsmedicin (CNS)
- Nils Larsson, statistiker, Avdelningen för försäkringsmedicin (CNS)

Projektledaren vid Karolinska Institutet har haft återkommande diskussioner med SRS-projektets ledning under hela projekttiden.

Jag hoppas att de här framtagna nya modellerna (SRS 2.2) ska underlätta för läkare i det viktiga och ibland problematiska arbetet med att hantera sjukskrivningsärenden ^{5,6}.

Stockholm 24/8 2021

Kristina Alexanderson
Projektledare, professor

Avdelningen för försäkringsmedicin
Institutionen för klinisk neurovetenskap
Karolinska Institutet, Stockholm

[Kristina.alexanderson@ki.se](mailto:kristina.alexanderson@ki.se)

Förkortningar

I rapporten används följande förkortningar och begrepp:

AIC	Akaike Information Criterion. Statistiskt kvalitetsmått rörande modellens kvalitet i förmåga att beskriva data jämfört med andra möjliga modeller.
Bruttodagar	Antal dagar med ersättning från Försäkringskassan för sjukskrivning eller sjuk- och aktivitetsersättning
BS	Brier Score. Statistiskt mått rörande modellens kvalitet i förmåga att korrekt estimeras sannolikheter. Likvärdigt Mean Square Error.
Faktor	Ett värde på en variabel, till exempel kvinna i variabeln kön
ICD-10	International Classification of Diagnoses, version 10 ⁷
IMAS	Insurance Medicine All Sweden; den databas projektet baseras på
LISA	Longitudinell Integrationsdatabas för Sjukförsäkrings- och Arbetsmarknadsstudier; rikstäckande register administrerat av Statistiska centralbyrån
Log-Likelihood	Ett statistiskt mått på sannolikheten över specifika värden av statistiska parametrar i modellen, givna observerade data
MAD	Mean Absolute Deviation, ett mått på hur spridd en fördelning är
MiDAS	MikroData för Analys av Socialförsäkringen; rikstäckande register administrerat av Försäkringskassan
Nettodagar	Antal <i>hela</i> dagar med ersättning från Försäkringskassan för sjukskrivning eller sjuk- och aktivitetsersättning där dagar med partiell frånvaro är hopslagna till hela dagar (t.ex. 2 dagar på halvtid blir en nettodag)
PCH	Piecewise Constant Hazards Model
Primärvård	Med primärvård avses här vård vid vårdcentraler, husläkarmottagningar, etc
RMSE	Root-mean-square error. Mått avseende en modells förmåga att estimeras ett utfall. Se BS.
Sekundärvård	Specialiserad öppenvård eller sjukhusvård (dvs vid inläggning på sjukhus)
SKR	Sveriges kommuner och regioner (tidigare SKL)
SRS	Stöd för rätt sjukskrivning; namn på det övergripande projekt som denna rapport ingår i
Totala antalet dagar	Antal dagar i ett sjukskrivningsfall, från och med anmälningsdagen till och med sista dagen med ersättning från Försäkringskassan
VAL	Namnet på register om primärvårdsbesök i Region Stockholm
Variabel	En grupp faktorer som utesluter varandra, till exempel kön som består av kategorierna kvinna och man

Bakgrund

Det projekt som kallas stöd för rätt sjukskrivning (SRS) drivs av Sveriges Kommuner och Regioner (SKR) och startade inom ramen för de överenskommelser som funnits mellan staten och SKR om en kvalitetssäker och effektiv sjukskrivnings- och rehabiliteringsprocess⁸⁻¹³. Inom SRS-projektet har bedömningsstöd för allmänläkares arbete med sjukskrivning av patienter tagits fram¹⁴. Karolinska Institutet har bidragit i detta arbete på flera sätt, bland annat genom litteraturgenomgångar¹⁵ samt genom att, via statistiska analyser av registerdata, ta fram och pröva prediktiva modeller för bedömning av risk att ett pågående sjukskrivningsfall ska bli mycket långt eller längre än förväntat¹⁻⁴. Syftet har varit att tidigt i sjukskrivningsprocessen och mer träffsäkert kunna identifiera sjukskrivna personer med en hög risk för längre sjukskrivning och det eventuella behovet av särskilda eller samordnade åtgärder, för att främja en snabbare återgång i arbete/sysselsättning. Bedömningsstödet har prövats i en pilotstudie och befunnits vara användbart¹⁴. Under år 2020 har Karolinska Institutet haft i uppdrag att uppdatera modellerna i bedömningsstödet, något som avrapporteras i detta projekt.

Detta delprojekt utgår från det arbete som gjorts av Karolinska Institutet i tidigare projekt inom ramen för SRS-projektet, avseende prediktion av fortsatt sjukskrivning bland personer som har påbörjat ett sjukskrivningsfall¹⁻⁴.

Syfte

Syftet med detta delprojekt var att uppdatera tidigare SRS modeller (2.0) av typ och avseende samtliga nya sjukskrivningsfall >14 dagar i Sverige under en 2,5-års period (1/1 2014 – 30/6 2016).

Material och metod

I detta projekt har fortsatta analyser genomförts avseende prediktion av sjukskrivningsfalls duration. Analyserna utgår från det arbete som gjorts i tidigare delprojekt inom ramen för SRS-projektet¹⁻⁴ och har utvidgats betydligt från de tidigare analyserna.

Uppdraget omfattade bland annat följande delar:

Utveckla SRS prediktiva modeller av typ PCH version 2.2 för samtliga 23 SRS-diagnoser (bilagor 1-4), för sjukskrivningsfall längre än 14 dagar som påbörjades under perioden 1/1 2014 – 30/6 2016. Två uppsättningar av modeller tas fram:

Del I. En uppsättning modeller utan information om diagnoskoder på subkategorinivå (dvs fyr- eller femställighetsnivå) för 18 stycken av de 23 utvalda diagnoserna. Dessa modeller är likvärdiga med tidigare utvecklade modeller (version 2.0). Föreslå lämpliga frågor och deras svar för de sex viktigaste prognosvariablerna som läkaren ska lägga in i modellen¹, för varje modell.

¹ Om läkaren inte vet vad som gäller för patienten är tanken att läkaren frågar patienten om denna information.

Del II: *En uppsättning modeller för 20 av SRS-diagnoserna, enligt resultat från tidigare uppdrag 2019, där även relevant information om diagnoskoder på subkategorinivå från sekundär- och primärvårdsdata från Region Stockholm inkluderas. Följande delmoment ingår i arbetet:*

- i. Utvärdera huruvida informationen om den 4-ställiga diagnoskoden ska inkluderas som variabel i aktuella modellen, eller om en modell ska anpassas för varje faktor av den 4-ställiga diagnoskoden (t.ex. en modell för F43.8, en modell för F43.1, osv).*
- ii. Föreslå lämpliga frågor och deras svar för de sex viktigaste prognosvariablerna som läkaren ska lägga in i modellen, för varje modell.*

Dessa delar rapporteras nedan.

Registerdata

Analyserna baseras på information inom forskningsprojektet Insurance Medicine All Sweden (IMAS) ¹⁶, som leds och administreras inom Avdelningen för försäkringsmedicin, Karolinska Institutet. De data som har analyserats innehåller avidentifierade individdata, länkade från olika rikstäckande register för de personer i arbetsför ålder som registrerats som boende i Sverige vissa år, samt data om primärvård för Stockholms län. Projektet har godkänts av den Regionala etikprövningsnämnden i Stockholm. För detta projekt har data från följande sju register använts:

Från Statistiska centralbyrån:

- *LISA* ¹⁷ (*Longitudinell Integrationsdatabas för Sjukförsäkrings- och Arbetsmarknadsstudier*); information om följande sociodemografiska variabler för året innan det studerade sjukskrivningsfallet påbörjades (2013-2016): ålder, kön, födelseland, högsta utbildningsnivå, yrke, sektor, familjesituation, civilstånd, boendekommun.

Från Socialstyrelsen

- *Dödsorsaksregistret*; information om datum för död 2014-2016.
- *Patientregistret*, dels från *Slutenvårdsregistret*, dvs sjukhusinläggningar: datum, antal dagar, samt huvud- och bidiagnoser under åren 2013-2016, dels från *Öppenvårdsregistret*, vad avser: datum samt diagnoser för läkarbesök i specialiserad öppenvård under åren 2013-2016. Detta register innehåller inte information om vårdbesök i primärvården.
- *Läkemedelsregistret*; information om utköp av receptbelagd medicin 2013-2016 (datum, ATC-kod).

Från Region Stockholm

- Information från VAL-databasen avseende besök i primärvården (datum, diagnoser) under perioden 2013-2016.

Från Försäkringskassan

- *MiDAS (MikroData för Analys av Socialförsäkringen)*¹⁸: information om sjukskrivningsfall som ersatts av Försäkringskassan under perioden 2013 – 1/8 2017. Ur registret hämtades information om sjukskrivningsfallens startdatum (startdatum 1 (=anmälningdatum) samt startdatum 2 vilket är den första dagen med ersättning från Försäkringskassan), slutdatum, omfattning (grad av deltid respektive om heltid), antal dagar med ersättning från Försäkringskassan (både brutto- och nettodagar), totala antalet dagar i fallet (inklusive dagar utan ersättning från Försäkringskassan), försäkradtyp (typ av sysselsättning) vid sjukskrivningsfallets start, sjukskrivningsdiagnos (huvuddiagnosen i den första sjukskrivningsperioden i sjukskrivningsfallet) samt om fallet påbörjades med förebyggande sjukpenning eller rehabiliteringspenning. Motsvarande information om sjuk- och aktivitetsersättningar (tidigare kallat förtidspension respektive sjukbidrag) inhämtades också från MiDAS. Detta innebär att information från både hel- och delfallsfiler i MiDAS har använts.

Information om sjukskrivningsdiagnos från Försäkringskassans MiDAS databas på treställighetsnivå för ICD-10 (International Classification of Diagnoses, version 10⁷) fanns tillgängligt. Det innebär att information om sjukskrivningsdiagnoser på mer detaljerad nivå inte funnits i projektet.

I MiDAS registreras sjukskrivningsfall där Försäkringskassan har betalat ut ersättning. Det innebär att för de flesta anställda, där arbetsgivaren betalar sjuklön under de första 14 dagarna i ett sjukskrivningsfall, saknas det information om sjukskrivningsfallet i MiDAS om fallet inte överstiger 14 dagar. För arbetslösa och vissa andra grupper för vilka Försäkringskassan betalar ut ersättning tidigare i sjukskrivningsfallet finns dock kortare fall registrerade i MiDAS. För att inte introducera en bias relaterat till dessa grupper inkluderades i detta projekt endast de sjukskrivningsfall som blev 15 dagar eller längre.

Tre mått på antal sjukskrivningsdagar

Tre variabler används för beskrivning av antal dagar i ett sjukskrivningsfall. Den första beskriver antalet dagar från anmälningdagen (startdatum 1) till den sista dagen med ersättning, alltså då sjukskrivningsfallet avslutades, detta kallas här för *totala antalet dagar* i fallet. När data från MiDAS inom ramen för projektet behandlades (datacleaning på engelska) slogs alla sjukskrivningsfall, som startade inom fem dagar efter att ett tidigare fall avslutats, samman med det tidigare fallet. Detta på grund av den så kallade återinsjuknanderegeln, som innebär att personen får ersättning från Försäkringskassan redan från dag 1 i det nya fallet. För sjukskrivningsfall med ersättningstyp "förebyggande sjukskrivning" under fallet användes 14 dagar som gräns för sammanslagning, på grund av att sådana fall ofta upprepas inom det tidsintervallet. Vid beräkning av *totala antalet dagar* inkluderades inte de mellanliggande dagarna, det vill säga dagar utan ersättning från Försäkringskassan togs inte med.

Den andra variabeln är antal *bruttodagar*, som beskriver antalet dagar med ersättning från Försäkringskassan. Dessa dagar är i de flesta fall lika med antalet dagar mellan den första dagen med ersättning (startdatum 2) och den sista dagen med ersättning (slutdatum), men det finns sjukskrivningsfall där det förekommer dagar mitt i fallet där ingen ersättning har

utbetalats, detta till exempel på grund av uttagen semester. Dessa dagar utan ersättning är inte medräknade i variabeln bruttodagar men de är medräknade i variabeln totala antalet dagar.

I den tredje variabeln har antal bruttodagar räknats om till antalet *nettodagar*, det vill säga, antalet hela dagar med ersättning från Försäkringskassan. Till exempel omräknas fyra bruttodagar med en omfattning om 25 % av heltid till en nettodag.

I dessa analyser har även de första 14 dagarna i sjukskrivningsfall som blev >14 dagar beräknats, baserat på den omfattning sjukskrivningsfallet hade dag 15 (25, 50, 75 eller 100 %).

Utfallsvariabel

Utfallet i de framtagna statistiska modellerna var durationen av ett sjukskrivningsfall. Detta mättes som det totala antalet dagar från sjukskrivningsfallets dag 1 tills det avslutades. I vissa analyser användes som utfall huruvida sjukskrivningsfallet blev längre än ett förbestämt antal dagar (vanligtvis 90).

Urvalskriterier

Av samtliga drygt 1,2 miljoner sjukskrivningsfall som påbörjades någon gång under 2,5-årsperioden från och med 1/1 2014 till och med 30/6 2016 och som blev 15 dagar eller längre och där personen, när fallet påbörjades, var i åldersspannet 18-64 år, valdes samtliga fall som började med förmånstypen sjukpenning, där den sjukskrivne hade bott i Sverige året innan fallet påbörjades, inom 18 förbestämda sjukskrivningsdiagnosgrupper för Del I, respektive 20 för Del II. Vilka dessa diagnoser är framgår av tabell 1 nedan.

För modellerna enligt Del II, samt tillhörande analyser, tillämpades även följande selektionskriterier:

1. Att den sjukskrivne hade bott i Stockholm året innan fallet påbörjades;
2. Att sjukskrivningsfallets diagnos var associerat med primär- och/eller specialistvård med en diagnos där på åtminstone 4-ställig diagnos enligt ICD-10, från under perioden mellan 6 dagar innan och 15 dagar efter sjukskrivningsfallets start.

Samtliga sjukskrivningsfall följdes tills de avslutades, eller i vissa analyser tills de blev längre än 90 dagar.

Antal inkluderade sjukskrivningsfall i respektive studerad diagnos, samt antal och andel av dem som blev längre än 90 dagar, enligt ovanstående kriterier, framgår av tabell 1. Där anges även antal av dessa sjukskrivningsfall där personen bodde i Region Stockholm när fallet påbörjades.

Tabell 1. Studerade sjukskrivningsdiagnoser; antal sjukskrivningsfall, andel av fallen som blev längre än 90 dagar, per inkluderad diagnosgrupp.

Diagnoskod, ICD-10	Diagnos	Antal sjukskrivningsfall (antal från Stockholm)	Sjukskrivningsfall som blev >90 dagar n (% av sjukskrivningsfallen)
F31	Bipolär sjukdom	9034 (2245)	6072 (67)
F32	Depressiv episod	74313 (14331)	42053 (57)
F33	Recidiverande depressioner	20508 (5075)	13191 (64)
F41	Andra ångestsyndrom	47040 (11586)	24016 (51)
F43	Anpassningsstörningar och reaktion på svår stress	161778 (35141)	77554 (48)
G56	Mononeuropati i övre extremitet	18428 (2806)	2566 (14)
I63	Cerebral infarkt orsakad av trombos i precerebrala artärer	3789 (680)	2931 (77)
M16	Höftledsartros	9058 (1587)	5297 (58)
M17	Knäartros	12818 (2097)	7135 (56)
M19	Andra artroser	6698 (1122)	3239 (48)
M23	Andra sjukliga förändringar i knäled	11226 (2950)	2495 (22)
M51	Andra sjukdomar i mellankotskivorna	11723 (2612)	5773 (49)
M53	Ryggsjukdomar som ej klassificeras annorstädes	7975 (1287)	3950 (50)
M54	Ryggvärk	79351 (15432)	24756 (31)
M75	Sjukdomstillstånd i skulderled	23948 (4165)	9459 (39)
M77	Andra entesopatier	11384 (1997)	3115 (27)
M79	Sjukdomstillstånd i mjukvävnad ej klassificerade annorstädes	29383 (5908)	10788 (37)
R52	Smärta och värk ej klassificerade annorstädes	6969 (1838)	2903 (42)
R53	Sjukdomskänsla och trötthet	7192 (1642)	2386 (33)
S52	Fraktur på underarm	13982 (2714)	2894 (21)
S62	Fraktur på handled och arm	12790 (2214)	1800 (14)
S82	Fraktur på underben, inklusive fotled	13823 (2895)	4770 (35)
S83	Luxation och distorsion av knäets leder och ligament	11859 (2175)	3350 (28)

Metoder för utvärdering av prediktionsmodeller

Utvärderingar av de framtagna modellerna har gjorts på flera sätt, såsom genom framtagande av AIC och Brier Score värden för modellerna, modellernas Goodness-of-fit och kalibrering respektive modellernas informativitet.

AIC, LogLikelihood och Brier Score

AIC, LogLikelihood och Brier Score (BS) användes för att jämföra två modeller anpassade till samma population (men möjligtvis med olika prediktorer – så kallad nested models): modellen med mindre AIC eller BS anses vara bättre anpassad till datat, respektive högre LogLikelihood. Brier Score definierades som Root Mean Square Error (RMSE) mellan den av modellen beräknade sannolikhet för $T > 90$ dagar och utfallet om sjukskrivningsfallet varade > 90 dagar. Notera att dessa mått inte får användas för att jämföra modeller anpassade till olika populationer.

Goodness-of-fit

Modellernas goodness-of-fit uppskattades med det så kallade Hosmer-Lemeshow test genom att beräkna sjukskrivningsfallets sannolikhet att överstiga sin observerad längd, alltså $P(T > t | x, \text{modell}, \theta)$ ¹⁹. Denna sannolikhet förväntas vara fördelad likformigt på intervallen $[0, 1]$ enligt teoremet Probability Integral Transform. Vi testade uniformiteten av modellens output grafiskt med en q-q graf. Q-q kurvan av en perfekt kalibrerad modell ligger på diagonalen

Kalibrering

Modellerna utvärderades avseende deras förmåga att korrekt uppskatta sannolikheten för att sjukskrivningsfallet överstiger 90 dagar. Utvärderingen syftar alltså på att svara på frågan: "När modellen beräknar patientens sannolikhet på 60 %, är bedömningen korrekt? Dvs av alla patienter som får en sannolikhet runt 60 %, blir ungefär 60 % av dem sjukskrivna längre än 90 dagar?".

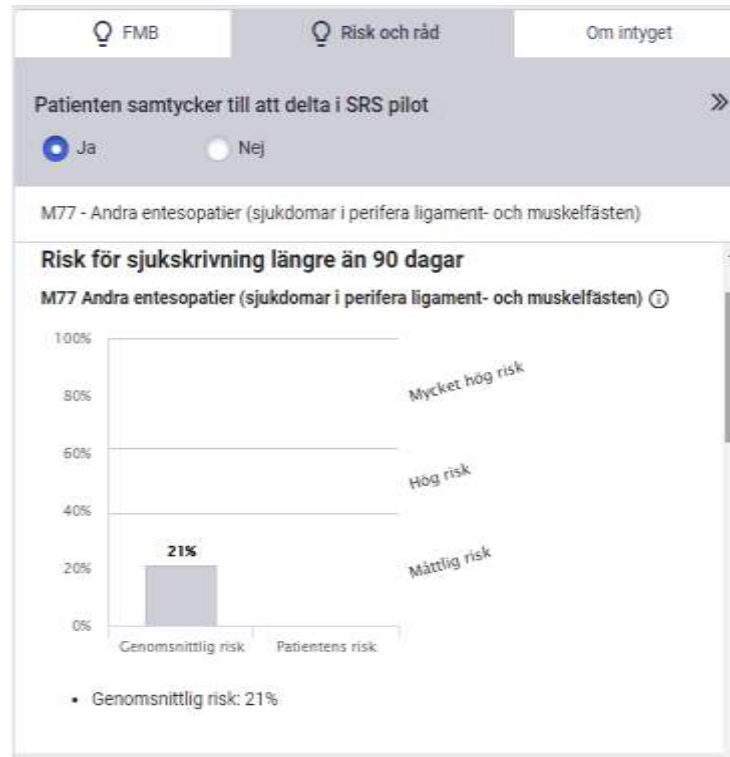
Modellernas kalibrering uppskattades genom att beräkna sjukskrivningsfallets sannolikhet att överstiga 90 dagar, alltså $P(T > 90 | x, \text{modell}, \theta)$. Denna sannolikhet förväntas överensstämma med den observerade andelen sjukskrivningsfall som överstiger 90 dagar. Den observerade andelen estimeras med en flexibel logistisk regression mellan den av modellen beräknade sannolikheten och utfallet (dvs huruvida sjukskrivningsfallet faktiskt överstiger 90 dagar). Den av modellen beräknade sannolikheten modelleras med en restricted cubic spline med 3 degrees of freedom och linjära svansar. I och med att kalibreringskurvan i sig är en prediktionsmodell med viss osäkerhet, visas nedan även konfidensintervallerna av kalibreringskurvan i diagrammen. Kalibreringskurvan av en perfekt kalibrerad modell ligger på diagonalen.

Informativitet

Inom SRS-projektet har vi även utvärderat modellernas förväntade beteende för avsett praktiskt användande. Modellerna kommer i praktiskt bruk att användas för att estimeras den sjukskrivne patientens sannolikhet för att vara sjukskriven längre än 90 dagar. Den beräknade sannolikheten presenteras grafiskt till läkaren i form av ett stapeldiagram där patientens sannolikhet redovisas tillsammans med medelsannolikheten för diagnosgruppen (se figur 1).

Syftet är att hjälpa läkaren att identifiera patienter med stor sannolikhet för långtidssjukskrivning.

Figur 1. Exempel på hur prediktionsmodellernas beräknade sannolikhet visas i SRS i Webcert



Utifrån detta har SRS-projektgruppen identifierat två mått för informativiteten, nämligen:

1. Mean Absolute Deviation (MAD), dvs medeltalet av den absoluta skillnaden mellan varje patients beräknade sannolikhet (för $T > 90$) och medelsannolikheten för aktuella diagnosen
2. ”Informativitet”, definierad som andelen patienter som får en beräknad sannolikhet (för $T > 90$) större än medelsannolikheten +10 % eller mindre än sannolikheten -10 %

Genom att ta fram siffror för dessa två mått kan man därför svara på frågorna:

1. I snitt, hur mycket skiljer sig en patients sannolikhet från medelsannolikheten för patienter sjukskrivna i samma huvuddiagnos?
2. Hur många patienter får en sannolikhet som är mer än 10 % större eller mindre än medelsannolikheten för patienter sjukskrivna i samma huvuddiagnos?

Ju högre dessa två mått är, desto bättre anses modellen vara. Observera att detta gäller förutsatt att modellen är välkalibrerad. Dessa mått ska med fördel inte användas för att jämföra modeller, utan snarare för att få en enkel förståelse för hur en modell skulle fungera i verkligheten.

Analysen i Del I

Analyserna syftade till att utifrån en lista på 14 möjliga prediktorer som identifierades i tidigare analyser inom SRS ⁴, identifiera de nio variabler med högst prediktiv kraft inkluderande tre förutbestämde variabler som alltid ska vara med (kön, ålder, geografisk ort) för var och en av sjukskrivningsdiagnoserna G56, I63, M16, M17, M19, M23, M51, M53, M54, M75, M77, M79, R52, R53, S52, S62, S82, S83; samt att utveckla modeller med de identifierade variablerna för var och en av dessa 18 sjukskrivningsdiagnoser. Dessa modeller är avsedda för bruk när information om den 4-ställiga sjukskrivningsdiagnoskoden inte är tillgänglig vid användning av SRS-bedömningsstödet.

Variablernas prediktiva kraft mättes med en step-forward variable selection scheme, med skillnaden i Log-Likelihood som mått för prediktiv kraft. Variabelselektionsstrategin:

1. Initialisera listan av kandidatvariablerna v vars prediktiva kraft ska bedömas
2. Initialisera listan av utvalda variabler, v_0
3. Anpassa en modell m_0 med variablerna v_0
4. För var och en av kandidatvariablerna v
 - a. anpassa en modell m_1 med variabler v_0 PLUS kandidatvariabeln
 - b. beräkna $DLogLik = LogLik(m_1) - LogLik(m_0)$
5. Selekt den kandidatvariabeln v_{new} från punk 2 som har störst $DLogLik$, och tillägg till v_0 . Ta bort v_{new} från v
6. Upprepa steg 3-5 tills v_0 har 6 variabler i sig

Sedan anpassades det en modell för varje studerad sjukskrivningsdiagnos med de variablerna som valdes med ovanstående metod. Modellerna utvärderades sedan avseende kalibrering, sin goodness-of-fit samt prediktiv förmåga. Modellerna och tillhörande dokumentation levererades till SRS-projektgruppen.

Variabler i Del I

Följande 14 variabler användes i analysen, där de tre första (kön, ålder, boenderegion) ingick i alla modeller, då denna information kan hämtas ur vårdcentralens datasystem (dvs, som inte behöver läggas in manuellt av läkaren):

- Kön (man/kvinna)
- Ålder det år sjukskrivningsfallet började
- Geografisk boenderegion (5 kategorier, motsvarande den regionindelning som Försäkringskassan använder)
- Tidigare sjukskrivning, under de 12 månaderna innan datum när detta sjukskrivningsfall påbörjades (antal bruttodagar, kategoriserat)
- Antal läkarbesök i specialiserad öppenvård under de 12 månaderna innan det datum för när detta sjukskrivningsfall påbörjades (mellan 0-medianen eller över median för antalet besök bland dem som hade besök)
- Antal dagar patienten varit inlagd på sjukhus under de 12 månaderna innan sjukskrivningsfallet påbörjades (mellan 0-medianen eller över medianantalet dagar bland dem som varit inlagda)

- Sysselsättningsstatus när sjukskrivningsfallet påbörjades (dikotomiserat föräldraledig/yrkesarbetande/studerande eller arbetslös)
- Högsta utbildningsnivå (dikotomiserat grundskola/gymnasium eller universitet)
- Sjukskrivningsgrad dag 15 i sjukskrivningsfallet (25/50/75/100%)
- Om personen hade en pågående partiell sjuk- eller aktivitetsersättning när sjukskrivningsfallet påbörjades (ja/nej)
- Födelseland (Sverige/Övriga världen)
- Familjesituation (sambo/gift eller ej)
- Antal uttag av receptbelagd medicin under de 12 månaderna före sjukskrivningsfallet påbörjades (minst två uttag i separat läkemedelskategori, definierat efter första positionen i ATC-koden, dikotomiserat: ja/nej)
- Om patienten varit inlagd respektive haft läkarbesök i specialiserad öppenvård i samband med att sjukskrivningsfallet startade (ja/nej)

Analyser i Del II

Analyserna syftade till att utveckla modeller för var och en av sjukskrivningsdiagnoserna F31, F32, F33, F41, F43, M16, M17, M19, M23, M51, M53, M54, M75, M77, M79, R52, R53, S52, S62, S82, S83 med – förutom de 14 variablerna rapporterade i Del I, även information avseende rapporterade diagnoskoder på subkategorinivå (endast koder under aktuella sjukskrivningsdiagnosen) i specialist- samt primärvården i en period mellan 6 dagar innan och 15 dagar efter starten av aktuella sjukskrivningsfallet. Syftet med dessa variabler var att försöka utvinna mer information om sjukskrivningsdiagnosen. Sjukskrivningsfall som var associerade med vård (huvud- eller bidiagnoser) för flera 4-ställiga diagnoskoder exkluderades i samtliga analyser.

Arbetet bestod av följande moment:

1. Undersöka huruvida informationen om diagnoskoder på subkategorinivå borde inkluderas som prediktor eller som stratifieringsvariabel. För detta syfte anpassades en modell med informationen som prediktor, samt en modell för varje värde av den subkategoriska diagnoskoden; dessa två uppsättningar modeller jämfördes sedan avseende sin förmåga att anpassa datat, mätt med Brier Score.
2. Identifiera vilka sex variabler med högst prediktiv förmåga utöver vissa förutbestämde variabler som alltid skulle vara med (kön, ålder, samt variabler om diagnoskoder på subkategorinivå) för var och en av de utvalda sjukskrivningsdiagnoserna. Samma metod som i Del I, det vill säga step-forward variable selection scheme.
3. Föreslå lämpliga frågor och svar för de sex viktigaste prognosvariablerna som läkaren kan ställa till för patienten, för varje utvald modell, enligt punkt 4.
4. Utveckla modeller med de identifierade variablerna för var och en av sjukskrivningsdiagnoserna.
5. Leverera modeller och dess dokumentation till SRS-projektgruppen.

Variabler i Del II

I denna del av analyserna prövades ytterligare variabler, baserade på rapporterade diagnoskoder för primär- och sekundärvård i Stockholms län. Nedan ges ett exempel på variabler som togs fram för analys av sjukskrivningsfall i diagnosen S62 (Fraktur på handled och hand). Variablerna inkluderade t.ex. information avseende följande typ av grupper:

1. Om patienten har fått någon typ av sjukvård (primärvård och/eller sekundärvård), för psykisk diagnos (samtliga F-diagnoser + Z73) under de senaste 12 månaderna, i förhållande till sjukskrivningsfallets startdatum
2. Om patienten har fått någon typ av sjukvård (primärvård och/eller sekundärvård), för en av följande diagnoser på subkategorinivå i samband med sjukskrivningsfallet (mellan 6 dagar innan och 15 dagar efter start av sjukskrivningsfallet). Variabeln är kategorisk, med värden som utesluter varandra. Exempel:
 - a. Fraktur på os scaphoideum (i hand) (S62.0)
 - b. Fraktur på karpal- eller metakarpalben (S62.1; S62.2; S62.3; S62.4)
 - c. Fraktur på fingrar (S62.5; S62.6; S62.7)
 - d. Fraktur på andra och ospecificerade delar av handled och hand (S62.8)

Motsvarande variabler togs fram för var och en av de resterande 19 diagnoserna.

Variabelgrupp 1 beräknades även för muskuloskeletal diagnos respektive för var och en av de andra somatiska diagnoserna; för sjukskrivningsdiagnoser i F- respektive M-gruppen exkluderades själva sjukskrivningsdiagnosen från beräkningen av variabelgrupp 1 (exempelvis samtliga diagnoser i M-kapitel exkl. M16).

Variabler i grupp 1 inkluderas i modellen utan att selekteras genom step-forward variable selection som ovan beskrivet.

För vissa diagnoser togs även fram variabler med andra grupperingar av ICD-koder på 5-ställig nivå, till exempel som anger om frakturen var öppen eller sluten. Dessa variabler ingick i step-forward variable selection. En lista med samtliga selekterade variabler anges nedan (tabell 4).

Resultat

Del I

Resultat för Del I består av 18 modeller med dess dokumentation. Modellerna har utvärderats på flera sätt. De olika utvärderingsmått på de slutgiltiga modellerna (Loglikelihood, AIC, Brier Score, MAD respektive informativitet) framgår nedan av tabell 2. Brier Score, informativitet samt MAD avser modellernas prediktiva förmåga att estimeras sannolikheten av att sjukskrivningsfallet blir längre än 90 dagar.

Tabell 2. Utvärderingsmått avseende de slutgiltiga modellerna.

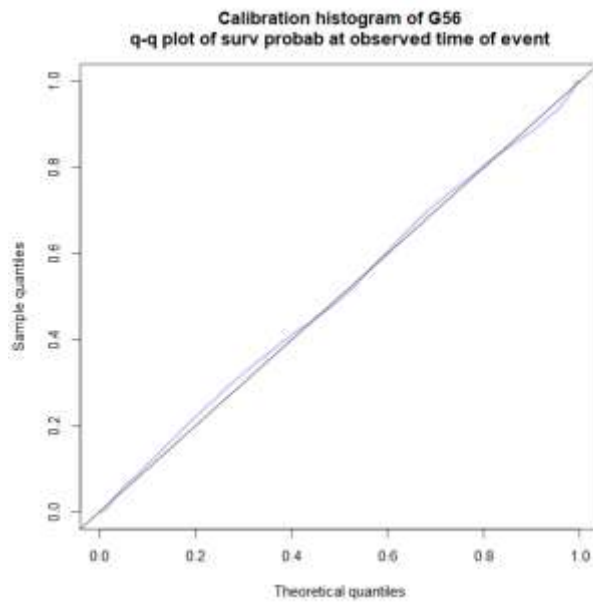
Diagnos	LogLikelihood	AIC	BrierScore	Informativitet	MAD
G56	-85661	171522	0.108	36	10
I63	-26076	52351	0.171	10	4
M16	-50836	101871	0.226	46	10
M17	-73701	147583	0.237	25	8
M19	-38916	78032	0.235	36	9
M23	-55231	110662	0.164	30	8
M51	-70207	140615	0.233	39	10
M53	-48184	96568	0.226	38	11
M54	-425452	851105	0.203	18	8
M75	-133756	267691	0.228	27	8
M77	-59292	118784	0.194	12	5
M79	-163582	327364	0.206	49	12
R52	-40096	80392	0.205	62	16
R53	-39528	79255	0.214	19	7
S52	-70093	140387	0.158	22	7
S62	-60533	121246	0.119	5	4
S82	-73694	147588	0.217	36	8
S83	-61373	122946	0.2	5	4

Goodness-of-fit

Ett goodness-of-fit test av modellerna genomfördes, för att utvärdera modellernas förmåga att uppskatta sannolikhet för långtidssjukskrivning. Resultat av dessa för diagnos G56 visas nedan i figur 2. Resultaten från motsvarande analys av resterande diagnoser framgår av Bilaga 1 (sid 25).

Samtliga modeller visade sig passa data bra.

Figur 2. Resultat av Hosmer-Lemeshow testet för sjukskrivningsfall i diagnosen G56.

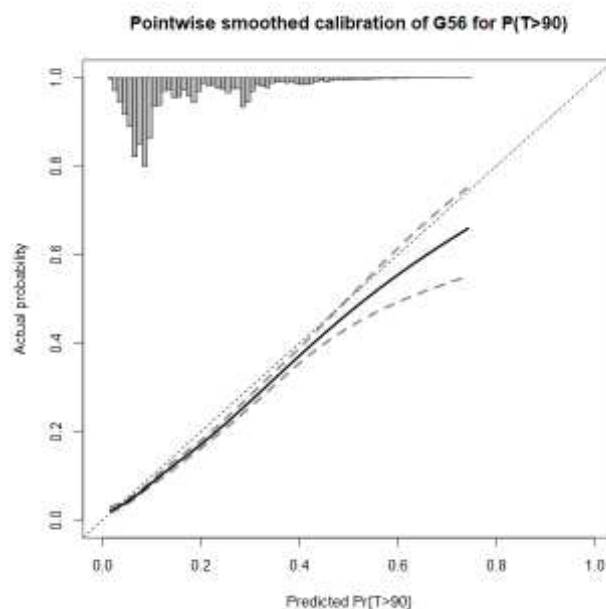


Kalibrering

Ett ytterligare test genomfördes för att utvärdera modellernas förmåga att korrekt uppskatta sannolikheten för att ett sjukskrivningsfall blir längre än 90 dagar. Resultat av dessa för diagnos G56 visas nedan i figur 3. Resultaten från motsvarande analys av resterande diagnoser framgår av Bilaga 2 (sid 27).

Samtliga modeller visade sig passa data bra.

Figur 3. Resultat av kalibrering testet för sjukskrivningsfall i diagnosen G56



Del II

Stratifiering

Analysen (som beskrivs ovan, punkt 1) utfördes för sjukskrivningsdiagnos F43. Modellen med information om diagnoskoder på subkategorinivå visade sig anpassa datat lika bra som modellerna stratifierade på de olika faktorerna i diagnoskoden, då dessa två olika uppsättningar modeller hade likvärdiga Brier Score (0.230 resp 0.229). Eftersom modellerna har likvärdig anpassningsförmåga och den ostratifierade modellen är mindre komplex, togs beslutet att inkludera information om diagnoskoder på subkategorinivå som prediktor, för samtliga aktuella sjukskrivningsdiagnoser.

Val av sex prediktorer

För varje diagnos togs en lista fram på de sex prediktorer med störst prediktiv styrka (utöver de ovannämnda förbestämda variablerna), samt ett mått på styrkan. Antalet resultat i dessa analyser är mycket stort och redovisas inte här.

Utvärderingar av slutgiltiga modeller

Modellerna har utvärderats på motsvarande sätt som i Del I. De olika utvärderingsmått på de slutgiltiga modellerna (Loglikelihood, AIC, Brier Score, MAD respektive informativitet) framgår nedan av tabell 3. Brier Score, informativitet samt MAD avser modellernas prediktiva förmåga att estimera sannolikheten av att sjukskrivningsfallet blir längre än 90 dagar.

Tabell 3. Utvärderingsmått avseende de slutgiltiga modellerna.

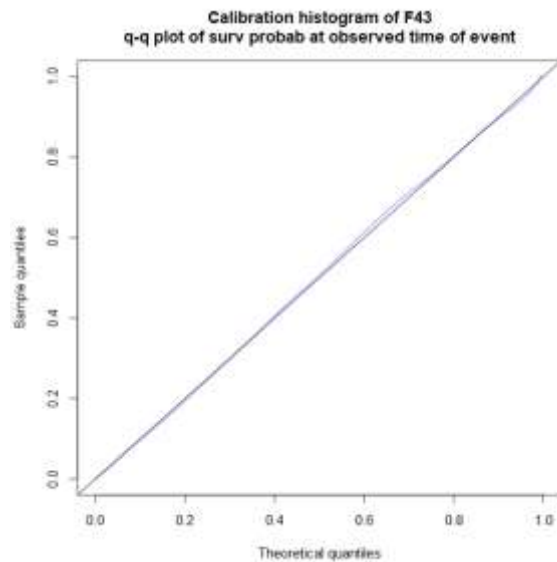
Diagnos	LogLikelihood	AIC	BrierScore	Informativitet	MAD
F31	-9374	18948	0.221	50	12
F32	-53049	106298	0.239	30	8
F33	-18448	37096	0.224	39	10
F41	-46890	93979	0.239	25	8
F43	-130753	261706	0.224	61	13
M16	-6731	13641	0.225	61	15
M17	-9073	18324	0.234	41	10
M19	-4424	9035	0.222	56	13
M23	-10586	21352	0.116	49	10
M51	-9120	18420	0.218	56	13
M53	-3716	7602	0.224	43	11
M54	-57106	114421	0.193	37	8
M75	-14045	28300	0.201	44	10
M77	-7127	14454	0.174	26	7
M79	-21490	43171	0.187	45	12
R52	-6233	12646	0.189	67	17
S52	-10808	21825	0.13	31	8
S62	-8387	16964	0.101	20	9
S82	-13468	27146	0.185	63	14
S83	-6828	13837	0.197	9	5

Goodness-of-fit

Resultat av dessa för diagnos F43 visas nedan i figur 4. Resultaten från motsvarande analys av resterande diagnoser framgår av Bilaga 3 (sid 29).

Samtliga modeller visade sig passa data bra.

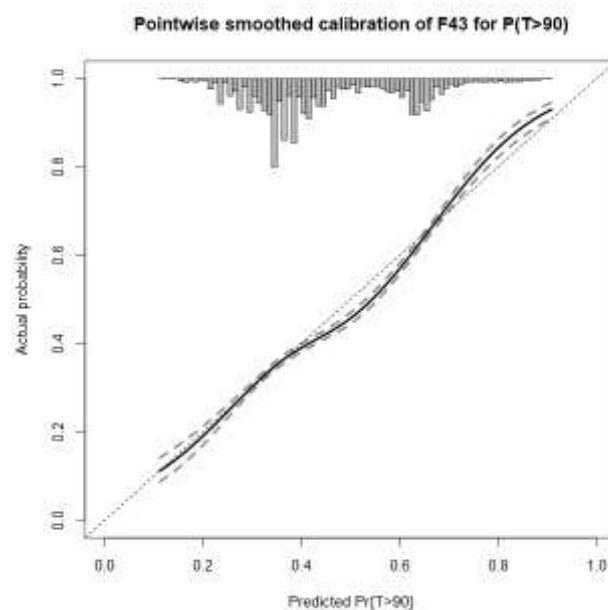
Figur 4. Resultat av Hosmer-Lemeshow testet för sjukskrivningsfall i diagnosen F43.



Kalibrering

Ett ytterligare test genomfördes för att utvärdera modellernas förmåga att korrekt uppskatta sannolikheten för att ett sjukskrivningsfall blir längre än 90 dagar. Resultat av dessa för diagnos F43 visas nedan i figur 5. Resultaten från motsvarande analys av övriga diagnoser framgår av Bilaga 4 (sid 31).

Figur 5. Resultat av kalibrering testet för sjukskrivningsfall i diagnosen F43.



Prognosvariabler, frågor och svar för användning av allmänläkare

Ett dokument togs fram med de sex variablerna med högst prediktivt värde för var och en av de utvalda diagnosgrupperna. I samtliga modeller läggs följande två variabler² in, samt variabler avseende ICD-koder på subkategorinivå, information som i praktiskt bruk kommer att hämtas från journalsystemet:

Kön: (kvinna, man)

Ålder: följande kategorier: 17-29, 30-39, 40-49, 50-56, 57-63 år

Resterande sex variabler och hur läkaren kan ställa frågor kring var och en av variablerna kan ställas samt för vilka diagnoser av de utvalda sjukskrivningsdiagnoser som respektive variabel är med i den prediktiva modellen framgår av följande tabell (tabell 4). Variablerna är listade i bokstavsordning baserat på variabelnamnet i datasetet. Svartalternativen är dikotoma (ja/nej) för samtliga variabler med ett undantag: sjukskrivningsgrad när fallet påbörjades; för denna variabel finns det fyra möjliga svartalternativ.

Tabell 4. Variabelnamn, frågetext att använda, samt för vilka diagnoser som respektive variabel ingår i modellen.

Variabelnamn i prediktiv modell	Frågetext	Diagnos(er) denna variabel används för
any_visits_-365_+6_Mental	Vård för psykisk diagnos senaste 12 månaderna	M19, M77, S52, S62
any_visits_-365_+6_Mental_notF32	Vård för annan psykisk diagnos än F32 senaste 12 månaderna	F32
any_visits_-365_+6_Mental_notF33	Vård för annan psykisk diagnos än F33 senaste 12 månaderna	F33
any_visits_-365_+6_Mental_notF41	Vård för annan psykisk diagnos än F41 senaste 12 månaderna	F41
any_visits_-365_+6_Mental_notF43	Vård för annan psykisk diagnos än F43 senaste 12 månaderna	F43
any_visits_-365_+6_Musc	Vård för muskuloskeletal diagnos senaste 12 månaderna	S83
any_visits_-365_+6_Musc_notM23	Vård för annan muskuloskeletal diagnos än M23 senaste 12 månaderna	M23
any_visits_-365_+6_Musc_notM54	Vård för annan muskuloskeletal diagnos än M54 senaste 12 månaderna	M54
any_visits_-365_+6_Musc_notM75	Vård för annan muskuloskeletal diagnos än M75 senaste 12 månaderna	M75
any_visits_-6_+15_S62_exposed	Öppen fraktur i handen	S62
any_visits_-6_+15_S82_exposed	Öppen fraktur i underbenet	S82
birth_cat_fct	Född i Sverige	F32, F43, M17, M23, M53, M75, M79, S52, S62, S82, S83
comorbidity	Annan långvarig/kronisk sjukdom	F32, F43, M51, M53, M54, M79, R52
DP_atStart	Sjuk- eller aktivitetsersättning på deltid i början av detta sjukskrivningsfall	F31, F33, M54
edu_cat_fct	Tagit högskolepoäng	F41, M16, M17, M19, M23, M51, M53, M75, M77, M79, S52, S82, S83

² Eftersom samtliga dessa analyser baserades på personer som bodde i Region Stockholm togs inte variabeln Geografisk ort med.

Fortsättning tabell 4		
fam_cat_4_cat_fct	Gift/sambo eller ensamstående/särbo	F31, S83
NoCareAtStart	Detta sjukskrivningsfall påbörjades inom primärvården	M16, M17, M19, M23, M51, M75, M77, R52
SA_1_gross	Haft annat sjukskrivningsfall som blev längre än 14 dagar senaste 12 månaderna	F31, F32, F33, F41, F43, M16, M17, M19, M23, M51, M53, M54, M75, M77, M79, R52, S52, S62, S82, S83
SA_ExtentFirst	Sjukskrivningsgrad i början av detta sjukskrivningsfall	F31, F32, F33, F41, F43, M16, M17, M19, M23, M51, M53, M54, M75, M77, M79, R52, S52, S62, S82, S83
SA_SyssStart_fct	Huvudsaklig sysselsättning vid detta sjukskrivningsfalls början	F31, F32, F33, F41, F43, M16, M17, M19, M51, M53, M54, M79, R52
Visits_yearBefore_all_r1_median	Fler än ett läkarbesök i specialiserad öppenvård (ej primärvård) senaste 12 månaderna	F31, F33, F41, M16, M77
Vtid_yearBefore_all_r1_median	Inlagd på sjukhus minst två dagar senaste 12 månaderna innan detta sjukskrivningsfalls början	R52, S52, S62, S82

Analyserna gjordes även för dag 30 i sjukskrivningsfallet, för att undersöka om andra modeller bör användas då. Analyserna visade att modellerna framtagna för dag 15 var lika bra.

Samtliga modellerna liksom dokumentet med frågorna har levererats till SRS-projektets ledning.

Slutkommentar

I dessa explorativa och omfattande analyser har syftet varit att ta fram användbara modeller för prediktion av om huruvida ett sjukskrivningsfall som pågått 15 dagar riskerar att bli längre än 90 dagar. Avsikten är alltså att modellerna ska användas på individnivå.

En prediktiv modell syftar till en god estimering av distributionen av en utfallsvariabel (y), baserat på en uppsättning möjliga prediktorer (x). Vi kan t.ex. predicera durationen av ett sjukskrivningsfall, baserat på individbaserad information om t.ex. ålder, kön, sjukvårdshistorik, yrke, etc. En prediktiv modells prestanda beror på styrkan i associationen mellan tillgängliga prediktorer och utfallsvariabeln ^{4, sid. 26 och Fig 2.}

Alla datasets har sina styrkor och tillkortakommanden. Om vi hade haft ytterligare information, såsom om sjukdomens/skadans allvarlighetsgrad, mer ingående information om samsjuklighet, patientens behandling och rehabilitering (både vad som erbjudits och vad som patienten deltar i), patientens livsstil (avseende t.ex. tobaksvanor, alkohol, droger, matvanor, etc) misshandel, krav i betalt och obetalt arbetet, möjligheter till anpassning av arbetet eller till annan typ av arbete, språkkunskaper, om sjukskrivande läkares och annan sjukvårdspersonals inställning till patienten och arbete/sjukfrånvaro, hade vi möjligtvis kunnat

få ännu bättre prediktiva modeller. Men bara möjligtvis. Mekanismerna bakom dessa synnerligen komplexa fenomen är än så länge endast undersökta i begränsad utsträckning ²⁰.

Ett problem med att, som i detta projekt använda MiDAS-data är att endast första sjukskrivningsdiagnosen i sjukskrivningsfallet finns registrerad, dvs det saknas information om huruvida sjukskrivningsdiagnosen ändras under sjukskrivningsfallets gång, respektive huruvida det finns information i läkarintyget om ytterligare diagnoser som kan ha bidragit till arbetsförmågan. Ett annat problem är att sjukskrivningsdiagnosen endast är angiven på treställighetsnivå. Inom t.ex. F43 finns det fyra olika diagnosgrupper på fyrställighetsnivå, och det är stora skillnader i förväntad sjukskrivningslängd mellan dessa fyra diagnoser ²¹. Vi försökte kompensera för denna begränsning genom att inkludera variabler med information om ställda diagnoser i primär- och sekundärvården (från PAR och för personer bosatta i Region Stockholm från VAL). Eftersom vissa modeller anpassades på sjukskrivningsfall för personer bosatta i Stockholm, kan detta ha introducerat bias i de estimerade parametrarna. En styrka är att den faktiska sjukskrivningslängden ingår, dvs den sjukskrivning (längd och grad) som patienten använt och som har godkänts av Försäkringskassan. Det är möjligt att variablernas betydelse i modellerna kan variera med förändrade socialförsäkringsregler, förändrad tillämpning av regler, samt förändring av sjuklighet och krav på arbetsmarknaden. Det vill säga, uppföljning av modellerna behövs.

Inom detta delprojekt, liksom inom de tidigare har vi utgått från sjukskrivningsfall i analyserna, inte från personer med nya sjukskrivningsfall. Nackdelen med att utgå från sjukskrivningsfall är att bias kan introduceras i analyserna om det genomgående är personer med vissa egenskaper som har fler än ett fall. Fördelen med att utgå från sjukskrivningsfall är framförallt att samtliga fall, dvs inte bara de som inträffar först under en inkluderingsperiod, bidrar med information i analyserna. Eftersom det endast var en mycket liten andel personer som hade fler än ett sjukskrivningsfall i bedömdes det viktigare att ha inkluderat fler fall i analyserna ^{3,4}. Eftersom antal dagar i sjukskrivningsfall under de 12 föregående månaderna också inkluderades i analyserna, hanterades detta delvis.













Referenser, urval







1. Alexanderson K, Bottai M, Frumento P, Hinas E, Nilsson K, Kjeldgård L, Tinghög P. Prediktion av fortsatt sjukskrivning respektive av långtidssjukskrivning bland sjukskrivna personer. Försäkringskassan och Sverige Kommuner och Landsting (SKL); 2016.
2. Hinas E, Nilsson K, Tinghög P, Mittendorfer-Rutz E, Alexanderson K. Prediktion av fortsatt sjukfrånvaro bland personer sjukskrivna i depressiv episod respektive i artros (Bilaga 5, Förstudierapport Stöd för rätt sjukskrivning; SRS). Försäkringskassan och Sverige Kommuner och Landsting (SKL); 2015.
3. Alexanderson K, Bottai M, Frumento P, Hinas E, Nilsson K. Prediktionsmodeller för sjukskrivningsduration. Bilaga 5, Stöd för rätt sjukskrivning. Stockholm: Karolinska Institutet/SKL; 2016.
4. Alexanderson K, Almondo G, Bottai M, Frimberg E, Frumento P, Granvald V, Josefsson P, Nilsson K, Sonden A. Prediktiva modeller för SRS piloten. Delrapport, reviderad. Avdelningen för försäkringsmedicin samt Enheten för biostatistik, Karolinska Institutet; 2018.
5. Alexanderson K, Arrelöv B, Friberg E, Haque M, Lindholm C, Svärd V. Läkares erfarenheter av arbete med sjukskrivning av patienter. Resultat från en enkät år 2017 och jämförelser med resultat från motsvarande enkäter år 2012, 2008 respektive 2004. Huvudrapport 2018.: Avdelningen för försäkringsmedicin, Karolinska Institutet; 2018.
6. Söderberg E, Lindholm C, Kärrholm J, Alexanderson K. Läkares sjukskrivningspraxis; en systematisk litteraturöversikt: Socialdepartementet; SOU 2010:107; 2010.
7. International Statistical Classification of Diseases and Related Health Problems 10th Revision, Version for 2007: WHO; 2010 [<http://www.who.int/classifications/icd/en/>].
8. Sjukskrivningsmiljarden: "Överenskommelse mellan staten och Sveriges Kommuner och Landsting om en kvalitetssäker och effektiv sjukskrivningsprocess 2014-2015". Stockholm: Regeringskansliet Socialdepartementet, Sveriges Kommuner och Landsting; 2014.
9. En kvalitetssäker och effektiv sjukskrivnings- och rehabiliteringsprocess. Överenskommelse mellan staten och Sveriges Kommuner och Landsting 2016. In: Socialdepartementet, editor. Stockholm: Socialdepartementet och Sveriges Kommuner och Landsting; 2015.
10. En kvalitetssäker och effektiv sjukskrivnings- och rehabiliteringsprocess. Överenskommelse mellan staten och Sveriges Kommuner och Landsting 2016. In: Socialdepartementet, editor.: Regeringskansliet, Sveriges Kommuner och Landsting; 2016.
11. En kvalitetssäker och effektiv sjukskrivnings- och rehabiliteringsprocess. Överenskommelse mellan staten och Sveriges Kommuner och Landsting 2017-2018. Regeringskansliet Stockholm: Socialdepartementet, Sveriges Kommuner och Landsting; 2017.
12. En kvalitetssäker och effektiv sjukskrivnings- och rehabiliteringsprocess. Överenskommelse mellan staten och Sveriges Kommuner och Landsting 2019. Stockholm: Regeringskansliet, Sveriges Kommuner och Landsting; 2018.
13. En kvalitetssäker och effektiv sjukskrivnings- och rehabiliteringsprocess. Slutredovisning av Socialstyrelsens utvecklingsinsatser inom överenskommelsen mellan staten och SKR. Socialstyrelsen; 2020. Report No.: Artikelnummer 2020-12-7053.
14. Stöd för rätt sjukskrivning. Stockholm: Sveriges Kommuner och Landsting; 2018 Oktober 2018.

15. Elrud R, Ljungquist T, Alexanderson K. Litteraturöversikt, grå litteratur. Bilaga till förstudierapport SRS. Stockholm: Försäkringskassan, Sveriges Kommuner och Landsting, Sektionen för försäkringsmedicin, Karolinska Institutet; 2015.
16. Alexanderson K. Insurance Medicine All Sweden (IMAS): Karolinska Institutet; 2021 [<https://ki.se/media/59474/download>].
17. Longitudinell Integrationsdatabas för Sjukförsäkrings- och Arbetsmarknadsstudier (LISA) 1990 till 2009. SCB; 2011.
18. MiDAS Sjukpenning och rehabiliteringspenning. Försäkringskassan; 2011.
19. Gneiting T, Balabdaoui F, Raftery A. Probabilistic forecasts, calibration and sharpness. *J Royal Stat Soc.* 2007;69:243-68.
20. Sjukskrivning - orsaker, konsekvenser och praxis. En systematisk litteraturöversikt. Stockholm: Statens beredning för medicinsk utvärdering (SBU); 2003.
21. Försäkringsmedicinskt beslutsstöd; diagnosspecifika rekommendationer <http://www.socialstyrelsen.se/riktlinjer/forsakringsmedicinsktbeslutsstod>: Socialstyrelsen; 2017

Bilaga 1: Del I – Goodness-of-fit diagram

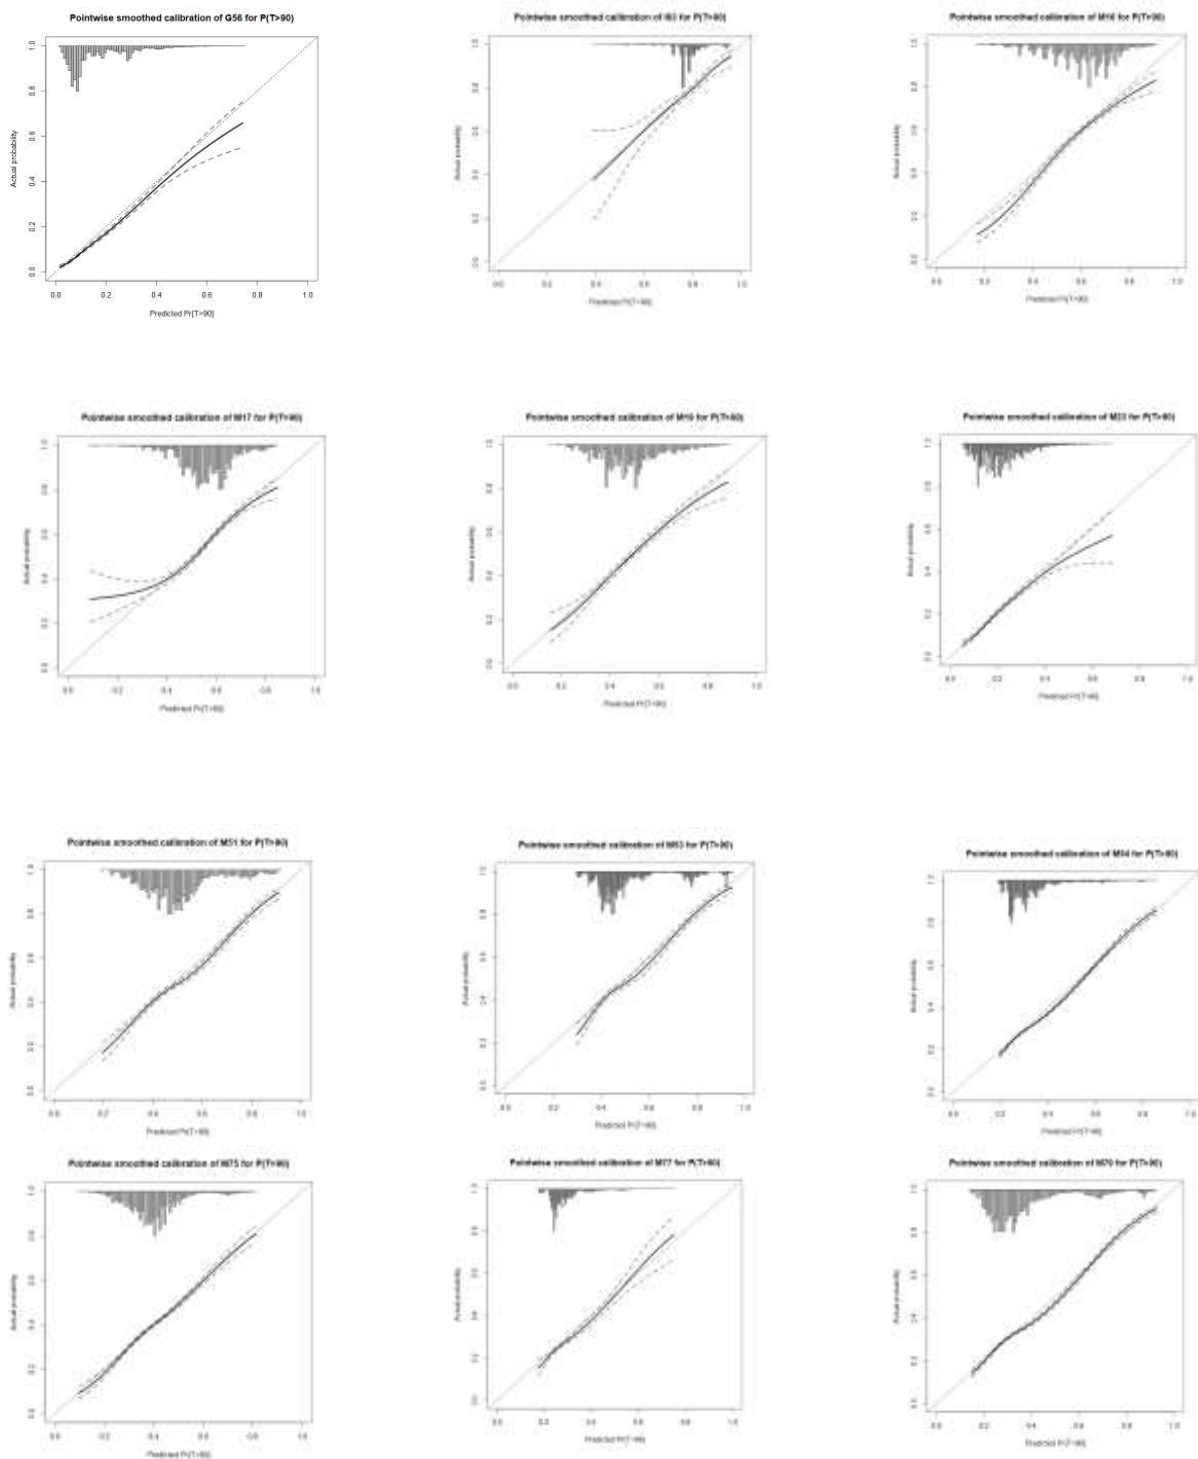
Figurer över resultaten från Hosmer-Lemeshow test (goodness-of-fit diagram) för var och en av de utvalda diagnoserna i Del I.











Bilaga 2: Del I – Kalibrering vid 90 dagar

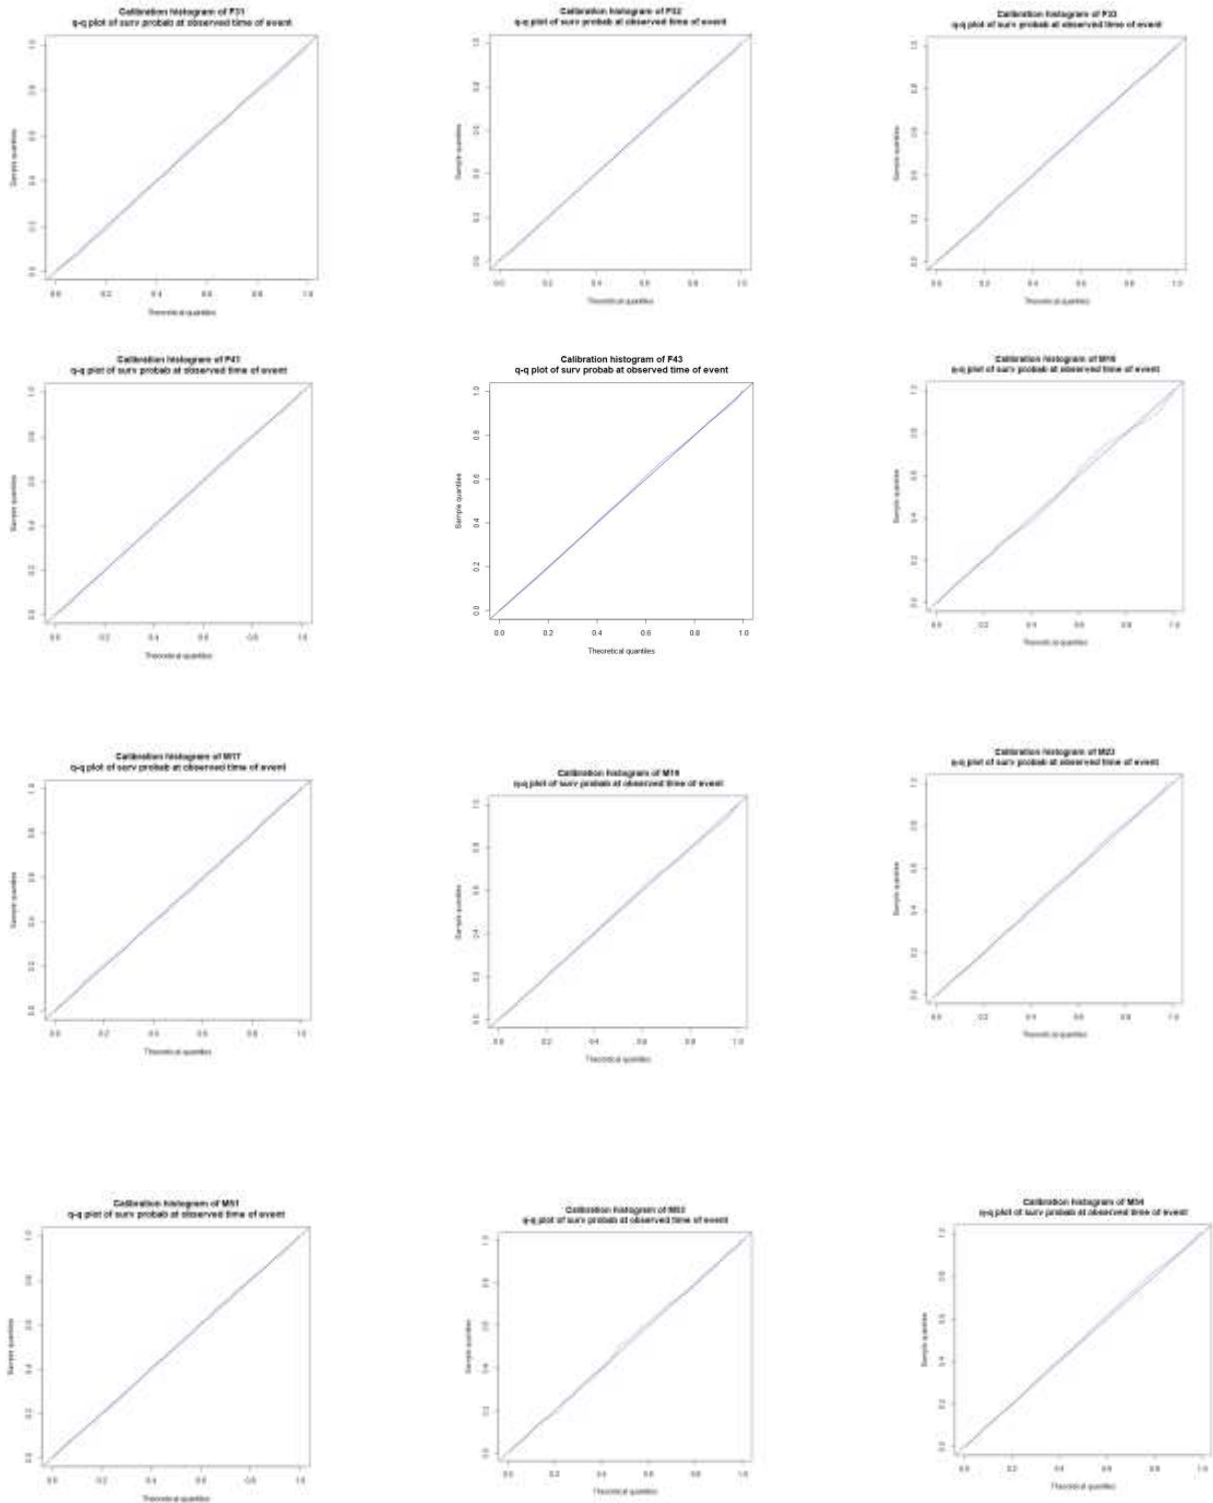
Figurer över resultaten från kalibreringstest för var och en av de utvalda diagnoserna i Del I. Testet utvärderar en modells prediktiva förmåga att uppskatta sannolikheten för att en sjukskriven patients sjukskrivningsfall blir längre än 90 dagar.













Bilaga 3: Del II – Goodness-of-fit diagram

Figurer över resultaten från Hosmer-Lemeshow test (goodness-of-fit diagram) för var och en av de utvalda diagnoserna i Del II.





Bilaga 4: Del II – Kalibrering vid 90 dagar

Figurer över resultaten från kalibreringstest för var och en av de utvalda diagnoserna i Del II. Testet utvärderar en modells prediktiva förmåga att uppskatta sannolikheten för att en sjukskriven patients sjukskrivningsfall blir längre än 90 dagar.

