

Matchning mellan läkare och patienter

Amanda Dahlstrand

Det finns betydande skillnader i läkares förmågor i olika uppgifter och det är inte samma läkare som är bäst på alla utfall. Denna rapport undersöker eventuella fördelar med att fördela läkare med specifika färdigheter i vissa utfall till högriskpatienter i dessa utfall. En sådan matchning visar sig kunna minska antalet undvikbara sjukhusinläggningar med 8 procent och antalet antibiotikaförskrivningar mot riktlinjerna med 3 procent. Dessutom finns potential att minska socioekonomisk ojämlikhet i samband med sjukhusinläggningar. Författaren använder data från digital vård som möjliggör kausal analys. Matchning är enklast att uppnå i digital vård men skulle även kunna användas i fysisk vård, åtminstone i regioner som har stort läkar- och patientunderlag.

Amanda Dahlstrand är Assistant Professor (universitetslektor) i nationalekonomi vid Zürich Universitet, nationalekonomiska fakulteten.

SNS ANALYS | En stor del av den forskning som bedrivs är vid sin publicering anpassad för vetenskapliga tidskrifter. Artiklarna är ofta teoretiska och inomvetenskapligt specialiserade. Det finns emellertid mycket forskning, framför allt empirisk och policyrelevant sådan, som är intressant för en bredare krets. Målet med SNS Analys är att göra denna forskning tillgänglig för beslutsfattare i politik, näringsliv och offentlig förvaltning och bidra till att forskningen når ut i medierna. Finansiellt bidrag har erhållits från Jan Wallanders och Tom Hedelius Stiftelse. Författarna svarar helt och hållet för analys, slutsatser och förslag.

»Digitaliseringen av tjänster har skapat nya möjligheter att undersöka kausala samband mellan vilken tjänsteutövare en viss person träffar och utfall.«

I. Introduktion

Var du bor har traditionellt avgjort tillgången till och därmed kvaliteten på tjänster som exempelvis sjukvård, utbildning och banktjänster. Möjligheterna att undersöka om alternativa matchningar mellan till exempel vårdgivare och patienter kan förbättra effektivitet eller jämlikhet, har i stor utsträckning varit begränsade eftersom fördelningen baserats på geografisk plats. Den ökande digitaliseringen av olika tjänster har dock skapat nya möjligheter att undersöka kausala samband mellan vilken tjänsteutövare en viss person träffar och utfall. I fysisk primärvård väljer läkare var de arbetar och patienter var de bor och var de söker vård. Det går inte att säkert veta om det är läkaren som orsakat bra patientutfall eftersom läkaren kan ha träffat patienter som är relativt friska eller ovanligt motiverade. Genom att fördela läkare och patienter så gott som slumpmässigt till varandra, givet kalenderdatum och tid på dagen, går det att få kausala estimat på hur läkare påverkar patientutfall.

I denna rapport, som bygger på forskningsartikeln *Defying distance? The provision of services in the digital age* (Dahlstrand, 2024), fokuserar jag på primärvårdsläkare och deras patienter och undersöker om matchningen mellan läkare, baserat på deras specifika färdigheter, och patienter, baserat på deras behov, kan förbättra sjukvårdens resultat och/eller minska ojämlikheten i vårdkvalitet mellan socioekonomiska grupper.

Studien bygger på ett dataset med konsultationer från en stor digital primärvårdsleverantör, och inkluderar 354 läkare och cirka 200 000 patienter. Datamaterialet är unikt eftersom patienter (under studieperioden) tilldelats första tillgängliga läkare i hela landet (med vissa restriktioner som analysen tar hänsyn till) via ett drop in-system. Den slumpartade matchningen var inte företagets huvudsyfte, men resultatet av dess ambition att minimera och jämnat ut väntetiderna nationellt. Datamaterialet har kopplats till såväl data från övrig sjukvård som demografiska och socioekonomiska data, och har anonymiserats av Statistikmyndigheten (SCB). En ytterligare fördel med datamaterialet är att varje läkare har ett anonymt identifikationsnummer, vilket generellt inte finns i registerdata om svensk vård. Detta möjliggör en utvärdering av läkares färdigheter i olika utfall och om vissa läkare är bättre än andra för vissa patienter.

Det är generellt svårt att mäta utfall av en primärvårdsläkares arbete; inom ett rimligt tidsintervall är de utfall som är mätbara ottydliga och de tydligt negativa (såsom dödsfall) är lyckligtvis mycket ovanliga för primärvårds-

patienter. För att mäta läkares färdigheter använder jag flera utfallsmått som tar hänsyn till olika aspekter av deras arbete, varav tre är viktigast: antibiotikaförskrivning mot riktlinjerna, undvikbara sjukhusinläggningar¹ och alla sjukhusinläggningar. Jag undersöker också behandling i övriga primärvården, och vårdkostnader efter läkarbesöket. Studien visar på betydande skillnader i läkares färdigheter inom dessa utfallsmått. Det verkar även som om läkare har olika styrkor och svagheter i olika utfall, det vill säga det är inte samma grupp läkare som är bäst i alla utfall, utan de har olika kompetenser. Detta beaktas sällan i organiseringen av primärvården eftersom förväntningen är att allmänläkare ska kunna hantera alla typer av uppgifter i denna vård.

Givet informationen om läkares färdigheter skulle det potentiellt vara möjligt att förbättra sjukvården genom att låta de läkare som är särskilt bra på vissa patientutfall arbeta med de patienter som har stor risk att drabbas av dessa utfall. Genom simuleringar analyserar jag effekterna av att kunna matcha läkares färdigheter och patienters behov. Patienters specifika behov definieras som deras risk att drabbas av olika negativa utfall, och mäts utifrån deras sjukvårdshistoria. En matchning mellan exempelvis en läkare med hög kompetens i att minska undvikbara sjukhusinläggningar och en patient som bedöms ha hög risk för sådana komplikationer, kan minska det totala antalet undvikbara sjukhusinläggningar. Studien visar att detta tillvägagångssätt inte har någon negativ effekt på andra mätbara utfall. Enligt Ellegård, Kjellsson och Mattisson (2022) är digital vård inte sämre än fysisk vård på att följa antibiotikariktlinjer, och Dahlstrand, Le Nestour och Michaels (2024) finner ingen skillnad i undvikbara sjukhusinläggningar mellan digitala och fysiska vårdmöten. Det tyder på att det inte är ett sämre läkarunderlag i digital vård än i fysisk, vad gäller två av de viktigaste utfall jag mäter i denna rapport, vilket förstärker generaliserbarheten av resultaten.

»Även om det är svårt att visa på kausalitet, har litteraturen visat att risken är högre att drabbas av negativa hälsoutfall för patienter med låg socioekonomisk status.«

Tidigare studier har visat att hälsa och sjukvård inte alltid är jämlik för patienter med olika socioekonomiska förutsättningar.² Även om det är svårt att visa på kausalitet, har litteraturen visat att risken är högre att drabbas av negativa hälsoutfall för patienter med låg socioekonomisk status jämfört med patienter med högre socioekonomisk status. Om de som har högre risk tilldelas läkare som är bra på att förebygga dessa utfall skulle det totala antalet negativa utfall kunna minska. Utifrån resultaten, att matchning på läkares färdigheter till patienter med stora behov kan minska det totala antalet negativa patientutfall, undersöker jag om dessa matchningar (vars mål är att

1. Sjukhusinläggningar som hade kunnat undvikas med korrekt primärvård i rätt tid. Konceptet finns i den medicinska litteraturen sedan 1990-talet och kan användas som mått på primärvårdens kvalitet. Måttet har utvecklats i den medicinska litteraturen sedan 1990-talet (Billings 1993, 1996) och mäter sjukhusinläggningar som kunnat undvikas med korrekt primärvård vid rätt tidpunkt. Definitionen i denna rapport baseras på Sundmacher med flera (2015). Jag tittar endast på US som sker 3–90 dagar efter det digitala sjukvårdsbesöket, eftersom primärvården sannolikt inte kan förhindra inläggningar dessförinnan.

2. För studier som rör Sverige, se exempelvis Chen, Persson och Polyakova (2022) som visar dels att det är större chans att en ungdom har fått HPV-vaccin vid 20 års ålder om föräldrarna har högre inkomst, dels att personer som har en läkare i familjen får bättre sjukvårdsutfall, och dels att det är vanligare bland personer med högre inkomst att ha en läkare i familjen. Se även Mörk, Sjögren och Svaleryd (2015) som visar att barn till föräldrar med låg inkomst har högre risk för att dö eller läggas in på sjukhus.

minska exempelvis undvikbara sjukhusinläggningar totalt) även skulle kunna minska den socioekonomiska ojämlikheten i patientutfall. Jag finner att detta är möjligt för till exempel undvikbara sjukhusinläggningar.

Analysen görs på data från digital vård; den slumpmässiga fördelningen som endast skett i digital vård är en förutsättning för att mäta kausala samband. En ytterligare fördel med den digitala vården är att matchning är möjlig över långa avstånd, men all primärvård går inte att utföra digitalt. För att kunna vidga slutsatserna från analysen undersöker jag under vilka förutsättningar det skulle vara möjligt att matcha läkare och patienter även i fysisk vård. Jag finner att det i en storstadsregion med många patienter och läkare och korta avstånd, troligen (endast vissa resultat i storstadsregionen är statistiskt signifikanta) går att uppnå ungefär samma matchningseffekter i hela landet, även om matchningen endast berör digitala läkare och patienter inom regionen. Avstånden är då inte längre än att patienten kan träffa samma läkare både fysiskt och digitalt. Det finns inte tillräckligt många observationer i glesbygd-regioner för att säga om det är möjligt även där, men det torde vara svårare att uppnå samma effekt på grund av färre läkare och längre avstånd.

Om det går att identifiera vilka läkare som har vissa färdigheter, skulle det då inte gå att anställa läkare som är skickliga inom alla utfallsområden? I ett tankeexperiment i sista delen av analysen jämför jag effekten av att genom simuleringar matcha läkares färdigheter och patienters behov med effekten av att (också genom simuleringar) öka andelen läkare som är bra på alla utfall (något som skulle kunna uppstå genom selektiv anställning eller som ett resultat av investeringar i kompetensutveckling). Analysen visar att effekten av att matcha läkare är större än effekten av att förbättra urvalet av läkare, vad gäller sjukhusinläggningar och undvikbara sjukhusinläggningar. För antibiotikaföreskrivningar mot riktlinjerna går det att se en liknande effekt av både förbättrat urval av läkare och matchning, men då endast från stora öknings- av generell kompetens, vilket kan vara svårt eller kostsamt att uppnå. Till skillnad från generella kompetensökningar kräver matchning inte nya resurser, som till exempel mer kompetenta läkare, utan enbart en mer effektiv användning av existerande resurser.

2. Data, metod och utfallsmått

I analysen används anonyma data från en stor digital primärvårdstjänst där patienter möter läkare i videosamtal. Under tidsperioden för denna studie (2016–2018) hade den digitala primärvårdstjänsten inga fysiska vårdcentraler och patienterna som använde den hade fortfarande kvar sin ordinarie fysiska vårdcentral. Dessa data har sedan kopplats till data från specialiserad öppenvård och slutenvård (all sjukvård vars data samlas in nationellt) samt läkemedelsföreskrivningar från både primärvård och specialiserad vård (det vill säga alla föreskrivningar som hämtats ut) från Socialstyrelsen. Socialstyrelsen samlar inte in data från primärvårdsbesök nationellt, så för primärvård har data kopplats till data från Region Skåne, främst för att kontrollera att primärvårdsrecept (som samlas in nationellt) är en rimlig proxy för fysiska primärvårdsbesök. Slutligen har data kopplats till demografiska och socioekonomiska data från SCB. Alla datakopplingar har utförts av SCB som även anonymiserat alla data.

Tabell 1 visar en jämförelse mellan de patienter som analysen baseras på, det vill säga de som använt den digitala primärvårdstjänsten och som ingår i

Tabell 1. Deskriptiv statistik och jämförelse med populationen.

	Artikels data	Nationellt medelvärde	Nationell data viktad på kommun	Nationell data viktad på kommun, kön och ålder
Storstadskommun	0,56	0,32	0,56	0,56
Kvinna	0,61	0,50	0,50	0,61
Ålder	30,3	40,8	39,8	30,3
Universitetsutbildning	0,55	0,38	0,43	0,50
Gift	0,32	0,42	0,41	0,34
Invandrabakgrund	0,17	0,24	0,27	0,30
Årsinkomst (tusental)	323,1	311,1	332,8	317,9

Not: Tabell 1 jämför patienter i studiens urval med hela svenska befolkningen. Notera att detta är en jämförelse med befolkningen och inte med övriga primärvårdsanvändare. Den första kolumnen rapporterar oviktade medelvärden för vilka de demografiska och socioekonomiska variablerna är definierade. Detta innebär att observationsantalet varierar mellan 147 069 för variabeln Universitetsutbildning och 215 739 för variabeln Kvinna. Universitetsutbildning redovisas för personer 23 år och äldre, och Gift för personer över 18 år. Invandrabakgrund är en indikator för personer som antingen är födda utanför Sverige eller har föräldrar som båda är födda utanför Sverige. Storstadskommun är en indikator för kommuner med storstäder. Inkomst inkluderar årsinkomster från lön och egenföretagande i tusentals kronor och redovisas för personer över 20 år.

artikelns (Dahlstrand, 2024) urval av 215 739 unika patientobservationer under 2016–2018, och övriga befolkningen.³ Det saknas data på nationell nivå över patienter som besöker den fysiska primärvården, vilket skulle varit den mest relevanta jämförelsen. Demografin hos patienter även i den *fysiska* primärvården ser lite annorlunda ut än hos befolkningen i stort, till exempel gällande kommun (storstadspatienter använder mer primärvård), kön (kvinnor använder mer)⁴ och ålder (äldre använder mer). Dessutom är socioekonomiska och demografiska variabler korrelerade, så för att få en bättre jämförelse i fråga om utbildning, inkomst, härkomst och civilstånd viktas medelvärdena i kolumn 3 och 4 först på kommun och sedan på kommun, kön och ålder.

Kolumn 1 visar medelvärden för artikelns urval och kolumn 2 det nationella medelvärdet. Den tredje kolumnen visar medelvärden som är justerade utifrån andelen patienter i respektive kommun. Den innehåller genomsnitt på kommunal nivå 2017 viktat utifrån förekomsten av kommunerna i studiens urval. Kolumn 4 visar de fyra sista variablerna viktade utifrån förekomsten av kommuner, kön och ålder i urvalet.

Tabellen visar att de som ingår i analysen i denna rapport skiljer sig något från befolkningen som helhet. Andelen som kommer från en storstadskommun är högre jämfört med befolkningen (56 procent jämfört med 32 procent). Det är större andel kvinnor än män i urvalet, precis som det är i den fysiska pri-

3. Jag använder endast ett besök per patient i digital vård.

4. I Region Skåne 2017 var 59 procent av alla läkarmöten med kvinnliga patienter – en liknande andel som i artikelns urval.

märvården. Patienterna är yngre än genomsnittet i både kommun och rike; tjänsten har varit populär bland småbarnsföräldrar (det är barnets ålder som registreras) och mindre populär bland äldre, till skillnad från den fysiska primärvården. Andelen gifta är lägre än genomsnittet i både land och kommun. Det kan delvis förklaras av det yngre urvalet, även om barn är exkluderade från variabeln Gift. Det är en lägre andel med invandrarbakgrund i urvalet jämfört med i riket och i kommunerna, vilket *inte* förklaras av ålder och kön i den fjärde kolumnen. Genomsnittsinkomsten är lägre än i kommunerna, vilket till viss del kan förklaras av den yngre åldern, men högre jämfört med landet som helhet, vilket delvis kan förklaras av överrepresentationen av storstadsregioner. Andelen som har universitetsutbildning är också högre, vilket i viss mån kan förklaras av att unga kvinnor har mer universitetsutbildning än män och att utbildningsnivån är högre i de kommuner varifrån patienterna kommer. Sammanfattningsvis, de främsta skillnaderna mellan patienter i analysunderlaget och patienter i befolkningen ligger i vilken sorts kommun de kommer från samt deras invandrarbakgrund.

»Analysen utnyttjar att läkare och patienter är slumpmässigt tilldelade varandra.«

2.1 SLUMPMÄSSIG FÖRDELNING

Analysen utnyttjar att läkare och patienter är så gott som slumpmässigt tilldelade varandra, villkorat av kalenderdatum och tid på dagen. Det är inte huvudsyftet med den studerade vårdtjänsten, utan resultatet av företagets ambition att minimera och jämma ut väntetiderna nationellt. Genom att läkare och patienter är slumpmässigt fördelade till varandra inom en tidsperiod, kan denna kvasi-randomisering användas för att få kausala estimat på hur en viss läkare påverkar patientutfall.

I den digitala tjänsten väljer läkarna sina arbetspass, ofta 2–3 veckor i förväg. Under sina arbetspass, när de inte är upptagna med en patient eller uppföljningsarbete (som att skriva recept), finns de med på listan över tillgängliga läkare. Ett undantag är om det finns en läkare på listan över tillgängliga läkare som har en specialistkompetens inom pediatrik. Då kommer denna läkare att vara mer benägen att matchas med barn som finns i patientkön. Därför exkluderar jag alla pediatrikska specialister och patienterna de matchas med. För statistiska tester av slumpmässigheten i fördelningen hänvisar jag till Dahlstrand (2024).

Vissa av de patienter som ingår i studien kunde välja mellan två alternativ: träffa första tillgängliga läkare (drop in) eller träffa en specifik läkare vid en angiven tidpunkt. För större delen av patienterna fanns endast drop in som alternativ. Totalt är det 82 procent av de totala antalet patienter under studieperioden som tilldelades eller valde drop in, och det är dem jag använder i analysen eftersom de slumpmässigt tilldelades en läkare bland de som var tillgängliga.

2.2 UTFALLSMÅTT

Målet med primärvårdsläkares arbete kan i det långa loppet sägas vara att deras patienter ska ha ett så friskt och långt liv som möjligt, givet begränsningen att den totala kostnaden för den sjukvård de får inte blir för hög (till exempel att sjukdomar tas om hand på rätt vårdnivå). Utfall kopplade till exempelvis livskvalitet är dock svåra att mäta. För att få ett mått på läkares effekt på kvalitetsjusterad livslängd krävs både en slumpmässig fördelning av patienter till

primärvårdsläkare och en uppföljning under en lång tidsperiod. Då detta hittills inte varit möjligt försöker jag i denna studie göra det mesta möjligt utifrån existerande data. Jag mäter utfall över en kortare tidsperiod, och försöker fånga sådant som mäter olika aspekter av primärvårdsläkares varierade uppgifter. Nedan följer en beskrivning av studiens utfallsmått.

Förskrivning mot riktlinjerna

En viktig uppgift för läkare i primärvården är att behandla vanliga infektioner enligt medicinska rekommendationer. Detta görs ofta med antibiotika och förskrivning är vanlig (dock inte vanligare i digital vård än i fysisk, se Ellegård, Kjellsson och Mattisson, 2022). För att motverka antibiotikaresistens finns därför riktlinjer som anger hur antibiotika bör förskrivas. Jag använder Stramas⁵ riktlinjer som vid tiden för studiens datainsamlingsperiod var de enda som anpassats till digital vård. Jag använder 16 riktlinjer som anger vilken typ av antibiotika (till exempel smalspektrum) som ska förskrivas vid olika diagnoser och för vilka diagnoser det inte är rekommenderat att förskriva antibiotika alls. Förskrivning mot riktlinjerna (FMR) mäter om en läkare har förskrivit ett recept (och patienten hämtat ut det) för antibiotika som inte stämmer med diagnoser enligt Stramas riktlinjer. Utfallet mäter alltså när en läkare skrivit ut för mycket eller för bred antibiotika. För att ta hänsyn till att läkare kan göra vissa undantag när det är medicinskt motiverat jämförs läkare som gör få undantag med läkare som gör många undantag, givet att de har liknande sammansättning av patienter.

Undvikbara sjukhusinläggningar

Undvikbara (eller påverkbara) sjukhusinläggningar/sjukhusvistelser (US) kan användas som mått på primärvårdens kvalitet. Måttet har utvecklats i den medicinska litteraturen sedan 1990-talet (Billings, 1993, 1996) och mäter sjukhusinläggningar som kunnat undvikas med korrekt primärvård vid rätt tidpunkt. Jag tittar endast på US som sker 3–90 dagar efter det digitala sjukvårdsbesöket, eftersom primärvården sannolikt inte kan förhindra inläggningar dessförinnan.

Alla sjukhusinläggningar

Då US är ett mycket ovanligt negativt utfall inkluderar jag även ett mer vanligt förekommande: alla sjukhusinläggningar inom 90 dagar efter det digitala sjukvårdsbesöket.

Behandling i annan primärvård

Det är också av intresse om patienter blir färdigbehandlade efter digital vård. Om patienter behandlas i övriga primärvården under den följande månaden kan det tyda på att deras aktuella åkomma inte kunde färdigbehandlas digitalt, eller på att de har en primärvårdskontakt av någon annan anledning. Då patienter är slumpmässigt fördelade till läkare borde det vara en liknande andel som behandlas hos de digitala läkarna och som månaden efter behandlas i primärvården av andra anledningar. Jag antar att de digitala läkare som har

5. Strama – Samverkan mot antibiotikaresistens – är en nationell arbetsgrupp som arbetar på uppdrag av Sveriges regioner.

högre andel patienter som efter behandling går till fysisk primärvård, färdigbehandlar färre patienter än andra läkare digitalt. Då jag inte har data på alla regioners fysiska primärvård, använder jag uthämtade recept som förskrivits i övrig primärvård inom 30 dagar efter det digitala sjukvårdsbesöket som en proxy. Läkemedelsregistret inkluderar förskrivningar i primärvården från hela landet. Jag exkluderar förskrivningar från den digitala vårdgivaren. Det finns dock två typer av mätfel kopplat till detta utfall. Personer kan hämta ut recept som tidigare förskrivits i primärvården utan att ha haft ett läkarbesök den månaden (typ I-fel eller falska positiva – 15,6 procent av dem som *inte* har ett läkarbesök i Region Skåne hämtar ut ett recept). Det kan också förekomma att personer hämtar ut recept som är helt orelaterat till vad de sökte digital vård för. Å andra sidan kan personer ha besökt primärvården utan att ha fått eller hämtat ut ett recept (typ II-fel eller falska negativa – 36,9 procent av dem som har ett möte hämtar inte ut ett recept). Dessa verkar dock kompensera varandra: i Region Skåne, där jag kan observera alla fysiska primärvårdsbesök, har 27,6 procent av de digitala patienterna ett fysiskt möte i övrig primärvård inom 30 dagar, och en liknande andel, 25,4 procent, hämtar ut ett recept från övrig primärvård. Eftersom detta är ett något otydligt utfall använder jag det mer som jämförelse med de andra utfallen – om en läkare är bra på att minska sjukhusvistelser, har den läkarens patienter mer övrig primärvårdsbehandling?

Kostnad

Ytterligare ett utfall att undersöka är om läkare i den digitala primärvården kan påverka de efterföljande kostnader som sjukvården har för varje patient. Jag undersöker om vissa läkares patienter har högre kostnader (kostnader för regionen) än andra läkares patienter efter besöket. Höga kostnader är inte nödvändigtvis dåligt; det kan antyda att patienten till exempel fått en remiss och kallelse till specialistvård för utredning av en potentiellt tidigare oupptäckt kronisk sjukdom. Men det skulle också kunna innebära att patienten har sökt vård på akutmottagning för något som hade kunnat behandlas inom primärvård, vilket är negativt. Då kostnad i vissa fall kan tyda på något positivt och i andra något negativt använder jag det mer som en kontroll av de andra utfallen – om en läkare är bra på att minska sjukhusvistelser, har den läkarens patienter högre kostnader inom övrig sjukvård? Sjukvårdskostnaderna inkluderar kostnader för alla förskrivningar (inklusive i primärvården), akutmottagningsbesök och specialistvårdsbesök som inträffar under 90 dagar efter det digitala besöket. Jag utesluter kostnader för sjukhusinläggningar, dels för att de dominerar alla andra kostnader (de få patienter som har sjukhusinläggningar har mycket höga kostnader), dels för att jag redan mäter dessa som ett separat utfall. Kostnader för primärvårdsbesök utesluts också då dessa data inte är nationellt insamlad. Mer detaljer om uträkningen och antaganden finns i Dahlstrand (2024).

2.3 ANALYS AV LÄKARES FÄRDIGHETER

Läkares förmågor, eller den påverkan läkare har på patientutfall, är mätt genom en metod som utvecklats i den nationalekonomiska litteraturen.⁶ Metoden bygger på att alla läkare får en liknande grupp patienter – i denna studie som ett resultat av en slumpmässig fördelning. Om det ändå finns en mindre skillnad mellan patientgrupperna kan detta hanteras genom att kontrollera för patientvariabler som exempelvis mäter deras tidigare antal sjukhusinläggningar och antibiotikaanvändning. Sedan jämförs patientutfallen mellan olika läkare. För en djupare beskrivning av metoden, se Dahlstrand (2024).

2.4 BERÄKNING AV PATIENTERNAS RISKER

För att kunna undersöka om läkare har olika effekt på olika patienter som kan grupperas baserat på tidigare sjukvårdsdata, skapar jag enkla mått på patienters risk för de olika utfallen. Jag hypotetiserar och verifierar senare att tidigare erfarenhet av varje utfall är en god prediktor för framtida utfall. Alltså mäter jag risken att uppleva ovan nämnda utfall genom tidigare utfall under de tre åren före det digitala sjukvårdsbesöket. Patienter bedöms ha risk för US om de haft minst en US under tre år, och på samma sätt för alla sjukhusinläggningar. Risken för FMR baseras på patienternas andel antibiotikarecept av alla uthämtade recept under tre år före mötet. Risken för primärvårds-läkemedelsbehandling i övrig primärvård baseras på antal primärvårds-recept uthämtade under tre år. Risken för höga kostnader baseras på patientens tidigare kostnader under de tre åren före besöket, där kostnader för bland annat sjukhusinläggningar (som har ett eget utfall och en egen riskvariabel) exkluderas.

3. Resultat

I detta avsnitt ger jag först en översikt över hur läkares förmågor varierar och eventuellt samvarierar. Variation i förmåga utgör en förutsättning för att det ska finnas någon poäng med att matcha läkare och patienter. Sedan visar jag i vilken utsträckning jag kan identifiera riskfyllda patienter med hjälp av tidigare sjukvårdsdata, vilket också är en förutsättning för matchning. Därefter följer huvudresultatet som visar i vilken utsträckning läkare med hög förmåga inom ett specifikt utfall har en ännu större effekt på patienter med beräknad hög risk för det utfallet. De avsnitt som sedan följer behandlar resultaten från olika kontrafaktiska simuleringar av matchning mellan patienter och läkare.

3.1 LÄKARES FÖRMÅGOR

Tabell 2 ger en översikt över hur läkares förmågor varierar och huruvida de olika förmågorna är korrelerade, exempelvis om de läkare som är särskilt bra på att följa riktlinjer för antibiotikaförskrivning är samma läkare som är särskilt bra på att förebygga undvikbara sjukhusinläggningar (US).

Den första raden visar standardavvikelser – ett mått på hur mycket läkarnas beräknade påverkan på patientutfall varierar mellan olika läkare. Under varje estimat står standardfelet inom parentes. Raden längst ner anger utfallets medelvärde och visar att 0,5 procent har en US inom 90 dagar; 1,7 procent

6. Bland annat av Chetty med flera (2014), Kline med flera (2020) och Rose med flera (2022).

Tabell 2. Variation i läkares förmågor.

	US	Sjukhus- inläggningar	FMR	Primärvård	Kostnad
Standardavvikelse	0,0049	0,0055	0,016	0,028	360,3
	-0,0015	-0,0023	-0,0026	-0,0085	-110,4
Medelvärde av utfallsvariabel	0,00512	0,023	0,0166	0,251	2 306,60

Not: Den första raden visar standardavvikelser med standardfel i parentes under. Sista raden visar medelvärdet av utfallsvariabeln. Antalet observationer varierar mellan 193 262 och 218 012, beroende på utfall. Standardfelen kommer från bootstrap med 500 iterationer.

av patienterna får och hämtar ut antibiotika mot riktlinjerna; 2,3 procent har en sjukhusinläggning inom 90 dagar; 25 procent hämtar ut ett recept från övrig primärvård inom 30 dagar; den genomsnittliga kostnaden (som exkluderar kostnader för bland annat sjukhusinläggningar och primärvårdsbesök) är 2 307 kronor under 90 dagar efter besöket.

Kolumn 3 i tabellen visar att en läkare som är en standardavvikelse bättre än medel på att följa antibiotikariktlinjerna har en effekt som är i princip lika stor som (utgör 96,4 procent av)⁷ medelvärdet av utfallsvariabeln. Alltså, för en patient som möter en läkare som är en standardavvikelse bättre än medelvärdet på att följa antibiotikariktlinjerna, minskar sannolikheten att få antibiotikaförskrivning mot riktlinjerna (FMR), från 1,7 procent (medelvärdet av utfallsvariabeln kan tolkas som när man möter en genomsnittlig läkare på detta utfall) till 0,06 procent.⁸ Tabellens första kolumn visar att en läkare som är en standardavvikelse bättre på att förebygga US har en effekt som utgör 95,7 procent av medelvärdet av utfallsvariabeln.⁹ En sådan läkare medför alltså att sannolikheten att en patient får en US minskar från medelvärdet 0,5 procent till 0,02 procent.¹⁰ För alla sjukhusinläggningar har läkare som är en standardavvikelse bättre på att förebygga dessa en effekt som utgör 23,9 procent av medelvärdet av utfallsvariabeln. Motsvarande estimat för behandling i primärvården är 11,2 procent och för kostnader (exkluderat bland annat sjukhusinläggning) 15,6 procent. Variation av läkares förmågor i de olika utfallen är alltså särskilt stor i att förebygga US samt i att följa antibiotikariktlinjer, vilket tyder på att matchning skulle kunna vara särskilt viktigt i dessa utfall.

I Dahlstrand (2024) finns även estimat av korrelationerna mellan läkares förmågor. De är mer osäkra än estimaten av standardavvikelseerna, men kor-

7. Standardavvikelsen på diagonalen genom medelvärde av utfallsvariabel:
 $0,016/0,0166 = 0,964$.

8. Medelvärdet $0,0166 - 0,964 * 0,0166 = 0,0005976$.

9. Standardavvikelsen på diagonalen genom medelvärde av utfallsvariabel:
 $0,0049/0,00512 = 0,957$.

10. Medelvärdet $0,00512 - 0,957 * 0,00512 = 0,00022$.

»Olika läkare är bra på olika saker.«

relationen mellan förmåga att följa antibiotika-riktlinjerna och förmåga att förebygga US verkar vara negativ (marginellt insignifikant). Detta antyder att primärvårdsläkare kan ha olika styrkor och svagheter, att olika läkare är bra på olika saker. Det saknas i alla fall stark evidens som tyder på att det är samma läkare som är bra på alla utfall.

3.2 RISKFYLLDA PATIENTER

En förutsättning för matchning mellan läkares förmåga och patienters behov är att kunna identifiera riskfyllda patienter baserat på information om tidigare sjukvårdsanvändning. De nedre raderna i tabell 3 visar att 4 procent av de patienter som jag identifierat som riskfyllda, baserat på om de haft en tidigare US, sedan faktiskt får en US inom 90 dagar efter det digitala vårdbesöket, medan endast 0,5 procent får det i genomsnitt.¹¹ Det innebär att en patient med hög risk för en US, identifierat på detta sätt, har mer än sju gånger högre risk för sådana inläggningar under 90 dagar efter besöket än medelvärdet bland alla patienter i urvalet.¹² En patient som har hög risk för generella (alla) sjukhusinläggningar har mer än dubbelt så stor sannolikhet för en sjukhusvistelse under de 90 dagarna efter besöket än medelvärdet.¹³

Riskvariabeln för de första två utfallen (US och sjukhusinläggning) är binär eftersom det är relativt ovanligt att ha haft fler än en sådan tidigare (4 procent har haft minst en US och 18 procent minst en sjukhusinläggning och det är dessa andelar som klassificeras som riskfyllda för respektive utfall). De sista tre utfallen (FMR, Primärvård och Kostnad) har kontinuerliga riskvariabler i den huvudsakliga analysen i tabell 3. För att kunna jämföra två riskgrupper även för de utfall som har kontinuerliga riskvariabler, definierar jag i de sista raderna i tabell 3 de patienter som är i högsta tiondelen (decilen) i risk som riskfyllda. De patienter som ligger i högsta decilen i risk för FMR har nära 18 procent högre risk för FMR under månaden efter det digitala besöket än medelvärdet.¹⁴ De patienter som ligger i högsta decilen i risk för behandling i fysisk primärvård har mer än dubbelt så mycket sådan behandling än de som ligger på medelvärdet under månaden efter det digitala besöket.¹⁵ De patienter som ligger i högsta decilen i risk för sjukvårdskostnader har mer än tre gånger så höga kostnader för sjukvård under månaden efter besöket än de som ligger på medelvärdet.¹⁶

11. Se raderna Medelvärde för hög risk och Medelvärde av utfallet.

12. Medelvärde för hög risk genom allas medelvärde: $0,039/0,0051 = 7,647$.

13. Medelvärde för hög risk genom allas medelvärde: $0,053/0,023 = 2,304$.

14. Medelvärde för hög risk (för de patienter som ligger i högsta decilen i risk för de kontinuerliga variablerna) genom medelvärde av utfallet: $0,020/0,017 = 1,176$, det vill säga 17,6 procent högre.

15. $0,60/0,25 = 2,4$.

16. $7\,207,3/2\,306,6 = 3,12$.

Tabell 3. Interaktionseffekter mellan läkarfärdighet och patientrisker.

	US	Sjukhusinläggning	FMR	Primärvård	Kostnad
Läkarfärdighet (standardiserad)	-0,00029 (0,00014)	-0,00067 (0,00031)	-0,010 (0,00043)	-0,013 (0,0016)	6,30 (4,09)
Patientrisk	0,028 (0,0020)	0,026 (0,0011)	0,0019 (0,00029)	0,10 (0,0039)	1 884,8 (18,6)
Färdighet * Risk	-0,0038 (0,0020)	-0,0022 (0,0011)	-0,00084 (0,00031)	-0,00031 (0,0032)	-1,78 (1,91)
Konstant	-0,00069 (0,00039)	0,0026 (0,00070)	0,015 (0,00080)	0,15 (0,0032)	1 878,5 (23,2)
Observationer	192,123	192,123	215,739	215,739	192,123
Medelvärde av utfallet	0,0051	0,023	0,017	0,25	2 306,6
Medelvärde för låg risk	0,0037	0,016	0,016	0,21	1 756,3
Medelvärde för hög risk	0,039	0,053	0,020	0,60	7 207,3

Not: Varje kolumn specificerar effekten i relation till olika utfall. Alla utfall förutom kostnad är binära indikationsvariabler. Kostnad är definierad kontinuerligt, men trunkerad på nittionionde percentilen. Läkarfärdigheterna är standardiserade. Patientriskvariablerna i de två första kolumnerna är indikatorer och i de tre sista är de kontinuerliga och standardiserade. Patientriskerna i de olika kolumnerna är följande: (1) indikator för US senaste tre åren, (2) indikator för en sjukhusinläggning senaste tre åren, (3) standardiserad andel antibiotika bland alla uthämtade förskrivningar senaste tre åren, (4) standardiserat antal förskrivningar från primärvård senaste tre åren, och (5) standardiserad och trunkerad kostnad från förskrivningar och öppenvård senaste tre åren (exkluderar bland annat sjukhusinläggningar och primärvårdsbesök). Standardfelen är klustrade på läkare. Regressionerna är skattade med fixa effekter och för datum och skift samt med kontroller för patientens kön, ålder och antal tidigare kroniska sjukdomar observerade i fysisk vård, enligt Elixhausers index, se Dahlstrand (2024) för mer detaljer. För medelvärdet i de sista två raderna representerar de första två kolumnernas värde andelen som haft en US eller sjukhusinläggning bland de som har haft/inte haft en US eller sjukhusinläggning tidigare. I de tre sista kolumnerna, där riskvariabeln i övriga tabellen är kontinuerlig, har hög risk på sista raden definierats som den högsta decilen i riskvariabeln. Detta för att kunna ge en jämförelse mellan de med hög risk och de med låg risk, precis som i de första två kolumnerna.

3.3 INTERAKTIONSEFFEKTER MELLAN PATIENTER MED STORA BEHOV OCH LÄKARE MED HÖG SPECIFIK FÖRMÅGA PÅ SAMMA UTFALL

Läkare med hög specifik kompetens har betydligt större påverkan på de riskfyllda patienterna än på övriga patienter i flera av utfallen. Läkare med en standardavvikelse högre förmåga i att förebygga US har fjorton gånger så stor effekt på patienter som beräknats vara riskfyllda för US än på övriga patienter.¹⁷ Läkare med en standardavvikelse högre förmåga i att förebygga generella sjukhusinläggningar har mer än fyra gånger så stor effekt på patienter som beräknats vara riskfyllda för sjukhusinläggningar än på övriga patienter.¹⁸

Nu går vi över från patienters riskvariabler som är binära till de som är kontinuerliga. Läkare med en standardavvikelse högre förmåga i att följa antibiotikariktlinjerna har 8,4 procent större effekt på patienter som har en

17. Den genomsnittliga effekten av läkarfärdighet jämförs med läkarfärdighetens effekter på riskfyllda patienter:

(Färdighet + Färdighet * Risk)/Färdighet: $(-0,00029 + -0,0038)/-0,00029 = 14,1$.

18. $(-0,0022 + -0,00067)/-0,00067 = 4,2$.

standardavvikelse högre risk för FMR än på övriga patienter.¹⁹ Gällande behandling i övrig primärvård är det möjligt att med precision (signifikant på 99 procents nivå) identifiera att läkare med högre kompetens har en effekt som sänker andelen som får behandling i övrig primärvård under 30 dagar efter besöket. Men här finns ingen interaktionseffekt; läkare med högre kompetens i detta utfall verkar inte ha en särskilt stor effekt på patienter med hög risk för ytterligare behandling. Detta indikerar att det inte är självklart att läkare med högre kompetens inom ett utfall alltid har en större effekt på patienter med högre risk. Anledningen i detta fall kan vara att vissa läkare är bättre på att färdigbehandla patienter digitalt och att detta gäller oavsett om patienten tidigare använt mycket primärvård eller inte.

Tabell 2 visar att standardavvikelsen av läkareffekten på kostnader är signifikant, även om den är liten jämfört med medelvärdet av utfallsvariabeln. I tabell 3 finns ingen signifikant läkareffekt eller interaktionseffekt på kostnader. Detta innebär att det är mindre troligt att det går att matcha patienter och läkare för att minska den kostnadsvariabel som används här. (Kom ihåg att den inte innefattar de största kostnaderna som kommer från sjukhusläggningar, eftersom de mäts separat i ett eget utfall. Om kostnader från sjukhusinläggningar skulle räknas med går det att matcha patienter och läkare för att minska dem, men sjukhusinläggningar mäts här som ett separat utfall.)

3.4 OMFÖRDELNINGSEFFEKTER

»Läkare som är särskilt bra på vissa utfall bör arbeta med högriskpatienter i de utfallen.«

Läkares förmågor i olika utfall varierar och de läkare som är särskilt bra på vissa utfall påverkar patienter som har högre beräknad risk i det utfallet mycket mer än vad andra läkare gör. Detta tyder på att det skulle kunna finnas möjligheter att förbättra sjukvården genom att låta de läkare som är särskilt bra på vissa utfall arbeta med högriskpatienter i de utfallen. I det följande analyseras hur stora de totala effekterna skulle bli genom kontrafaktiska simuleringar, vilka använder sig av de estimerade effekterna av läkares förmågor och matchningseffekter med olika patientgrupper från ovanstående avsnitt. Simuleringarna skattar och summerar effekterna för alla de patienter som kontrafaktiskt »byter« läkare, både de som får en läkare med *lägre* specifik förmåga inom ett område som de har låg risk för, och de patienter som får läkare med *högre* specifik förmåga i det område de har hög risk för. Eftersom det visar sig att läkare har olika förmågor i flera olika utfall, och eftersom det skulle kunna bli effekter på till exempel FMR från en matchning som endast försöker minimera US, undersöks effekterna på alla utfall vid varje simulering.

Den kontrafaktiska matchningen är baserad på patienters långsamt rörliga variabler, till exempel andel antibiotika av alla förskrivningar under tre år, eller antal sjukhusinläggningar under tre år. Detta innebär att den föreslagna matchningen inte behöver vara en enstaka läkarkontakt som bygger på de symptom patienten har för tillfället, utan skulle kunna vara en långtidskontakt.

Den första kontrafaktiska simuleringen²⁰ visar att om fokus ligger på att minimera FMR – så att läkare med hög förmåga att minska FMR matchas med patienter som har hög risk för FMR – så skulle det *totala antalet* FMR

19. $(-0,00084 + -0,010)/-0,010 = 1,084$.

20. För grafer av de kontrafaktiska simuleringarna, se Dahlstrand (2024). Där kan även konfidensintervall avläsas.

kunna minska med 3 procent (statistiskt signifikant). De andra utfallen varken ökar eller minskar, vilket tyder på att det är möjligt att minska FMR utan negativa bieffekter på US, alla sjukhusinläggningar, behandling i annan primärvård eller de kostnader som mäts.

Den andra kontrafaktiska simuleringen visar att om fokus ligger på att minimera US, genom att matcha läkare som är duktiga på detta med patienter med hög risk för US, skulle det totala antalet US kunna minska med 8 procent (statistiskt signifikant). De andra utfallen varken ökar eller minskar, vilket tyder på att det är möjligt att minska US utan negativa bieffekter på de andra utfallsmåtten.

Den tredje kontrafaktiska simuleringen visar att om fokus ligger på att minimera alla sjukhusinläggningar, skulle det totala antalet kunna minska med 3 procent (statistiskt signifikant) genom att omfördela läkare och patienter. De andra utfallen varken ökar eller minskar signifikant (det går, logiskt nog, att se en liten minskning även i US, men den är inte statistiskt signifikant), vilket tyder på att det är möjligt att minska sjukhusinläggningar genom matchning utan negativa bieffekter på de andra utfallsmåtten.

Intressant nog finns det inga omfördelningseffekter på utfallen primärvårdsbehandling eller kostnader (kom ihåg att kostnader är definierat utom kostnader för bland annat sjukhusinläggningar). Detta är för att det inte finns interaktionseffekter för dem (jämför tabell 3). Även om det finns variation i hur bra olika läkare är på utfallen, har läkare med hög förmåga ingen extra effekt på de patienter som har hög primärvårdsanvändning eller höga tidigare kostnader.


3.5 EFFEKTER PÅ SOCIOEKONOMISK OJÄMLIKHET

Den fysiska sjukvården är inte helt jämlik, vilket indikeras av analysen i Dahlstrand (2024). Där visas, både med data från Region Skåne och från hela landet, att patienter i områden med lägre socioekonomisk status är mindre nöjda med den fysiska primärvård de får. För Skåne redovisas även data på två objektiva utfall (andel som får träffa en läkare i stället för annan profession, och andel som får en rekommenderad läkemedelsbehandling), varav det ena är signifikant lägre i områden med lägre socioekonomisk status. Däremot visar figurerna 1, 2 och 3 i denna rapport (de ljusa staplarna) att andelen patienter i de olika inkomstdecilerna (en uppdelning av patienter i tio lika stora inkomstgrupper), som möter en läkare som är särskilt bra i vart och ett av de tre primära utfallen inom digital vård, är likartade.²¹ Den slumpmässiga fördelningen i digital vård har lett till en jämlik fördelning av läkares färdigheter över patienter med olika socioekonomisk status.

Analyserna ovan visar (med hjälp av den slumpmässiga fördelningen) att matchning på förmåga och behov kan förbättra utfallen så att de blir ännu bättre än vid slumpmässig fördelning. Nu undersöker jag hur dessa simulerade omfördelningar, vars mål är att förbättra de totala utfallen, påverkar tillgången


21. I detta avsnitt använder jag bara de tre första utfallen eftersom de två sista inte hade interaktionseffekter och därmed inte är aktuella som utfall att minimera genom matchning. Fördelningen av läkares färdigheter i de andra utfallen är också jämlik över inkomstdeciler i den faktiska slumpmässiga allokeringen, se Dahlstrand (2024). Notera att jag har fått utelämna patienter utan inkomstuppgift, framför allt barn, från dessa grafer.

Figur 1. Andel som möter topp 10 procent-läkare i förebyggande av US.



Not: X-axeln visar patienternas inkomstdeciler. Inkomst är förvärvsinkomst för vuxna patienter 2017. Barn är inte med i figuren då de inte har inkomstuppgift.

Figur 2. Andel som möter topp 10 procent-läkare i förebyggande av sjukhusinläggning.




Not: X-axeln visar patienternas inkomstdeciler. Inkomst är förvärvsinkomst för vuxna patienter 2017. Barn är inte med i figuren då de inte har inkomstuppgift.

»Den slumpmässiga fördelningen i digital vård har lett till en jämlig fördelning av läkares färdigheter över patienter med olika socioekonomisk status.«

till läkare med olika förmågor till patienter med olika inkomst, så att den socioekonomiska gradienten i sjukvård förändras.

När jag i simuleringar matchar för att minimera US och alla sjukhusinläggningar, får patienter med lägre inkomst en större andel läkare som är särskilt bra på att förebygga dessa utfall (figur 1 och 2). Den lägsta inkomstdecilen (de lägsta 10 procenten i inkomstfördelningen inom urvalet av vuxna) får 40 procent fler läkare med specifik förmåga att förebygga US (läkare som är i den högsta decilen i denna förmåga) – de går från cirka 11 procent till omkring 16 procent av sådana läkare (figur 1). Detta för att det är patienter med lägre

Figur 3. Andel som möter topp 10 procent-läkare i förebyggande av FMR.



Not: X-axeln visar patienternas inkomstdeciler. Inkomst är förvärvsinkomst för vuxna patienter 2017. Barn är inte med i figuren då de inte har inkomstuppgift.

inkomst som har högst risk för US, ett samband som inte bara uppmäts i denna studie utan även i flera andra länder. En sådan matchning skulle alltså leda till en mer ojämlik *tilldelning* av läkare än i den digitala vårdens slumpmässiga fördelning som var helt jämlik.²² Kvalitativt samma mönster gäller för totala sjukhusinläggningar (figur 2). Vad gäller FMR är omfördelningen kvalitativt den motsatta – här skulle patienter i den lägsta inkomstdecilen få färre läkare med just den specifika kompetensen (figur 3). Detta för att det inte är denna grupp patienter som i störst utsträckning verkar få och hämta ut relativt mycket antibiotika, och därmed behöver de inte läkare som är särskilt duktiga på att vara strikta och tydliga med riktlinjerna.

3.6 OMFÖRDELNINGSEFFEKTER INOM ETT MINDRE GEOGRAFISKT OMRÅDE (EN REGION)

All primärvård går inte att genomföra digitalt. Ett sätt att hantera detta är att erbjuda digifysisk vård, där varje vårdcentral erbjuder både digitala och fysiska möten.²³ De tidigare omfördelningseffekterna tillät läkare och patienter över hela landet att matchas med varandra. En viktig fråga är därför: Hur mycket av omfördelningseffekterna går att uppnå om vi begränsar det geografiska området, så att patienterna kan träffa samma läkare när de behöver fysisk vård och när de behöver digital vård? Svaret blir sannolikt olika för glesbygdsregioner och storstadsregioner. I tätbefolkade regioner finns det fler potentiella läkare inom ett rimligt avstånd och det går därför bättre att matcha patienter och läkare inom fysisk eller digifysisk vård där. I mindre tätbefolkade regioner

22. I simuleringen skulle matchningen bli progressivt ojämlik i stället för regressivt ojämlik, men mer jämlika utfall då de som har sämst utfall får störst förbättring. Samtidigt skulle de totala utfallen förbättras (som diskuterats ovan).

23. Dahlstrand, Le Nestour och Michaels (2024) studerar med kausal ansats skillnader i kvalitet och kostnader mellan digital vård och fysisk, gällande patienter som erbjuds båda vid digifysiska vårdcentraler.

däremot kan den digitala vården vara viktigare eftersom avstånden är längre; det finns färre potentiella läkare inom ett rimligt avstånd.

För att kunna undersöka om matchning kan hjälpa i glesbygdsregioner krävs tyvärr ett mer omfattande datamaterial (gällande antalet patienter och läkare i glesbygdsregioner). I Region Stockholm finns däremot ett större antal patienter och läkare i det existerande datamaterialet. Om jag simulerar matchning med restriktionen att patienter och läkare enbart får matchas inom Region Stockholm, ser jag omfördelningseffekter som är ganska lika dem som jag fick över hela landet. Men, osäkerheten (konfidensintervallet) är betydligt större på grund av att antalet patienter och läkare är färre (se Dahlstrand, 2024). Endast effekten för sjukhusinläggningar är statistiskt signifikant. Detta visar att det troligen går att uppnå liknande förbättringar i utfall inom en storstadsregion som att omfördela patienter inom digital vård över hela landet (till läkare över hela landet). Men med den fördelen att läkare och patient kan träffa varandra kontinuerligt, både fysiskt och digitalt.

3.7 JÄMFÖRELSE MED ATT ANSTÄLLA LÄKARE MED HÖGRE KOMPETENS PÅ FLERA OMRÅDEN

Om det går att mäta hur skickliga läkare är på att uppnå olika utfall, varför inte se till så att sjukvården anställer fler av dem som är bra inom alla områden? Skulle effekterna bli större eller mindre än effekterna från matchning med existerande läkare?

Genom att öka arbetad tid för läkare som har goda färdigheter (är över medianen) i *alla* de tre utfallen som gav effekt i matchningen (FMR, US och alla sjukhusinläggningar) med 50 procent (så att de går från att utgöra 13,5 procent av alla läkartider till att utgöra drygt 20 procent), och behålla den slumpmässiga fördelningen, uppnås en effekt på FMR som är ungefär lika stor som den från matchningen för att minimera FMR.²⁴ Dock uppnås ingen signifikant effekt på US eller alla sjukhusinläggningar (se figurer i Dahlstrand, 2024). Genom att drastiskt öka tiden med 100 procent, alltså dubblera tiden som läkare som är särskilt bra på alla tre utfall arbetar, till 27 procent av alla läkartider, uppnås 6 procents förbättring på antibiotikaföreskrivningar, en icke-signifikant effekt på alla sjukhusinläggningar och knappt 1 procents förbättring på US (signifikant endast på 90 procents nivå).

Detta visar att för vissa utfall (US och sjukhusinläggningar) är det mer effektivt att matcha patienter och läkare än att försöka anställa generellt bättre läkare. Det som utmärker de utfall där effekten av matchning är större, är att läkarnas effekt på icke-riskfyllda patienter är mindre – interaktionseffekten med patientrisk för US och sjukhusinläggningar dominerar bas-läkareffekten, medan det är tvärtom för utfallet FMR, där läkare har en ganska stor effekt för alla patienter. Genom att anställa läkare med högre generell kompetens kan effekten för FMR bli större. Dock är frågan hur svårt eller dyrt det är att anställa läkare med högre kompetens inom alla områden, då läkare är en begränsad resurs och det är svårt att mäta deras färdighet *innan* de anställs. Matchningen kräver inga ytterligare läkarresurser, och en läkares färdigheter kan mätas i början av anställningen genom att tilldela läkaren ett antal slumpmässiga patienter.

»En läkares färdigheter kan mätas i början av anställningen genom att tilldela läkaren ett antal slumpmässiga patienter.«

24. Därmed minskar arbetstiden för andra läkare med motsvarande antal timmar.

4. Slutsatser

Digitaliseringen av exempelvis vården öppnar nya möjligheter som beslutsfattare bör bli informerade om, så att de kan besluta om huruvida vårdens organisation behöver en översyn givet dessa nya möjligheter. Vården har flera utmaningar, exempelvis produktivitet, kostnader och jämlikhet. Många har pekat på att primärvården är nyckeln till både besparingar och jämlikhet. Denna rapport visar på en tidigare förbisedd möjlighet som digital vård öppnat upp: matchning mellan läkare och patienter.

Forskningsartikeln som ligger bakom denna rapport innehåller en utvärdering av flera möjligheter som digitaliseringen möjliggjort genom följande förändringar: (a) potentialen att direkt kunna se allokeringsmekanismen mellan läkare och patient, och därmed kunna studera läkares effekter kausalt utan snedvridning från selektion, (b) att direkt kunna använda data om både patienter och läkare för att sammanföra dem som passar bäst, och (c) att det finns fler läkare tillgängliga för varje patient då man digitalt kan träffas över längre avstånd – ett större urval möjliggör en bättre matchning.²⁵ Artikeln är den första att kausalt visa på (1) att läkare i primärvården har olika färdigheter inom US, FMR och sjukhusinläggningar,²⁶ (2) att patienters olika behov kan förutspås med hjälp av tidigare sjukvårdsdata, och (3) att totala utfall kan förbättras genom matchning mellan läkares förmågor och patienters behov.

En implikation av denna rapport, som är applicerbar på både fysisk och digital vård, är att det är användbart att följa utfall efter primärvård för att mäta skillnader i kvalitet. Jag visar också att kunskap om patienters sjukvårdsbakgrund, till exempel deras användning av antibiotika eller deras US, är viktig för att kunna ge dem rätt insatser. Ett sätt att utnyttja läkares olika kompetenser fullt ut är att matcha deras specifika kompetens med patienters behov. Detta verkar för vissa viktiga utfall (alla sjukhusinläggningar och US) ha större effekt (och är potentiellt mer genomförbart) än att försöka anställa läkare med bättre kompetens på alla områden. Dessutom går det att se en minskning av ojämlikhet i utfall mellan socioekonomiska grupper i vissa matchningar.

Digitaliseringen av exempelvis vården skapar med andra ord möjligheter. Men det finns också hinder för att möjliggöra förändring; mycket primärvård behöver utföras fysiskt, och det kan vara betydelsefullt att patienter träffar samma läkare både digitalt och fysiskt. Dock har de flesta vårdgivare i Sverige och i andra länder börjat med digifysisk vård; de erbjuder både digitala och fysiska besök. En sådan typ av vård gör att man för den digitala delen fortfarande kan använda sig av möjligheterna (a) och (b). Dock blir (c) inte en lika stor ny möjlighet i digifysisk vård om man vill ha kontinuitet mellan den läkare som patienten möter digitalt och fysiskt. Därför utvärderar föreliggande rapport också möjligheten att uppnå förbättringar från matchning *inom en region* (tidigare har jag fokuserat på hela landet), där det är rimligt att patienten kan möta samma läkare fysiskt när det behövs. Resultaten visar att det troligen går att uppnå liknande förbättringar från matchning i en storstads-

25. Dahlstrand (2024).

26. Detta är högst praktiskt relevant. Vissa regioner arbetar redan aktivt med att försöka mäta och jämföra primärvårdens resultat. Till exempel arbetar Region Halland med att jämföra olika primärvårdscentraler (inte enskilda läkare, delvis på grund av de svårigheter att göra detta i fysisk vård som jag nämnt ovan). De har också funnit att de mest relevanta utfallsmåtten är olika typer av sjukhusinläggningar.

region som Stockholm, där det finns många potentiella läkare inom ett rimligt avstånd. Datamaterialet är inte tillräckligt omfattande för att avgöra om det är möjligt i glesbygdsregioner. Men jag antar att det inte är möjligt och att dessa regioner står inför ett val: Vad är viktigast, matchning (för de digitala mötena) eller kontinuitet (mellan de digitala och de fysiska mötena)? Detta får framtida forskning utvisa.

Referenser

- Billings, J., Zeitel, L., Lukomnik, J., Carey, T. S., Blank, A. E. och Newman, L. (1993). Impact Of Socioeconomic Status On Hospital Use In New York City. *Health Affairs*, 12(1):172–173.
- Billings, J., Anderson, G. M. och Newman, L. S. (1996). Recent Findings On Preventable Hospitalizations. *Health Affairs*, 15(3): 239–249.
- Chen, Y., Persson, P. och Polyakova, M. (2022). The Roots of Health Inequality and the Value of Intra-Family Expertise. *American Economic Journal: Applied Economics*, 14(3): 185–223.
- Chetty, R., Friedman, J. N. och Rockoff, J. E. (2014). Measuring the Impacts of Teachers I: Evaluating Bias In Teacher Value-Added Estimates. *American Economic Review*, 104(9), 2593–2632.
- Dahlstrand, A. (2024). *Defying Distance? The Provision of Services in the Digital Age*. Mimeo. https://www.dropbox.com/scl/fi/hvupwkp6c0lrkx7yloos8/Defying_Distance_Dahlstrand.pdf?rlkey=nwb65aahpmjliza49vdyqkf69&dl=0.
- Dahlstrand, A., Le Nestour, N. och Michaels, G. (2024). *Online versus In-Person Services: Effects on Patients and Providers*. Mimeo.
- Ellegård, L. M., Kjellsson, G. och Mattisson, L. (2022). An App Call a Day Keeps the Patient Away? Substitution of Online and In-Person Doctor Consultations Among Young Adults. Mimeo. Working Paper in Economics No. 808. Department of Economics 2021, reviderad 2022. Göteborgs universitet.
- Kline, P., Saggio, R. och Sølvsten, M. (2020). Leave-Out Estimation of Variance Components. *Econometrica*, 88:1859–1898.
- Mörk, E., Sjögren, A. och Svaleryd, S. (2015). Hellre rik och frisk: Om familjebakgrund och barns hälsa. IFAU rapport, 2015. https://www.ifau.se/globalassets/pdf/se/2015/r-2015-13-hellre_rik_och_frisk.pdf.
- Rose, E. K., Schellenberg, J. och Shem-Tov, Y. (2022). The Effects of Teacher Quality on Adult Criminal Justice Contact. NBER Working Paper 30274. <https://www.nber.org/papers/w30274>.
- Sundmacher, L., Fischbach, D., Schuettig, W., Naumann, C., Augustin, U. och Faisst, C. (2015). Which hospitalisations are ambulatory care-sensitive, to what degree, and how could the rates be reduced? Results of a group consensus study in Germany. *Health Policy* 119(11):1415–23.

SNS Förlag
Box 5629, 114 86 Stockholm
Telefon: 08-507 025 00
info@sns.se www.sns.se

SNS – Studieförbundet Näringsliv och Samhälle – är en oberoende ideell förening som genom forskning, möten och utbildning bidrar till att ledande beslutsfattare i näringsliv, politik och offentlig förvaltning kan fatta välgrundade beslut baserade på vetenskap och saklig analys. 280 ledande företag, myndigheter och organisationer är medlemmar i SNS.