

PREDIKTION AV RETINOPATI OCH NEUROPATI VID TYP 1- DIABETES

Prestanda hos SVM-RBF och Random
Forest och klinisk acceptans

PREDICTION OF RETINOPATHY AND NEUROPATHY IN TYPE 1 DIABETES

Performance of SVM-RBF and Random
Forest and Clinical Acceptability

Examensarbete inom huvudområdet
informationsteknologi

Grundnivå 30 Höskolepoäng
Vårtermin 2026

Kasper Jungmalm Henriksson

Handledare: Christian Lennerholt
Examinator: Mikael Berndtsson

Sammanfattning

Mikrovaskulära komplikationer, såsom diabetisk retinopati och diabetisk neuropati, är allvarliga konsekvenser av typ 1-diabetes och tidig upptäckt är viktig för att minska risken för synnedbrott eller nervskada. Denna studie undersöker om maskininlärning kan användas för att prediktera dessa komplikationer och jämför två modeller: SVM-RBF och Random Forest. Studien bygger på ett utdrag ur det Nationella Diabetesregistret (NDR) och kompletteras med semi-strukturerade intervjuer med beslutsfattare inom diabetesvården för att bedöma modellernas kliniska acceptans som beslutsstöd.

Studien har en tvåfasig metodansats där första fasen använder experiment där modellerna tränas och utvärderas med hjälp av prestandamått såsom AUC, precision, recall, F1-score, missfrekvens och FP-frekvens. Den andra fasen använder semi-strukturerade intervjuer för att fånga kliniska acceptanskriterier.

Resultaten visar att Random Forest presterade bäst för retinopati med AUC 0,82, missfrekvens på 18 % och FP-frekvens på 35 %. För neuropati presterade SVM-RBF bäst med en AUC 0,76, missfrekvens på 34 % och FP-frekvens på 26 %. Intervjuerna visade samtidigt att beslutsfattare inom diabetesvården såg modellerna främst som beslutsstöd, att en låg felmarginal (5–10 %) efterfrågas och modellens förklarbarhet är centralt för att skapa tillit till modellerna. Ingen av modellerna uppnådde den acceptansnivå som beskrevs som kliniskt acceptabel av beslutsfattare.

Slutsatsen är därmed att maskininlärning har potential att stödja tidig identifiering av mikrovaskulära komplikationer hos typ 1-diabetiker, men att modellernas praktiska användbarhet begränsas av obalans i datamaterialet och kliniska acceptanskrav.

Nyckelord: typ 1-diabetes, T1D, mikrovaskulära komplikationer, diabetisk retinopati, diabetisk neuropati, SVM-RBF, Random Forest, klinisk acceptans, beslutsstöd, prediktion, prediktiv analys, maskininlärning

Abstract

Microvascular complications such as diabetic retinopathy and diabetic neuropathy are serious consequences of type 1 diabetes, and early detection is important to reduce the risk of vision loss and nerve damage. This study investigates whether machine learning can be used to predict these complications and compares two models: SVM-RBF and Random Forest. The study is based on an extract from the Swedish National Diabetes Registry (NDR) and is complemented by semi-structured interviews with clinicians within diabetes care to assess the clinical acceptability of the models as decision support.

The study is comprised of two phases. In the first stage, experiments are conducted in which the models are trained and evaluated using performance metrics such as AUC, precision, recall, F1-score, miss rate and false positive rate. In the second stage, semi-structured interviews are conducted to capture clinical acceptability criteria.

The results show that Random Forest performed best for retinopathy, with an AUC of 0,82, a miss rate of 18 % and a false positive rate of 35 %. For neuropathy, SVM-RBF performed best, with an AUC of 0,76, a miss rate of 34 % and a false positive rate of 26 %. The interviews showed that clinicians within diabetes care primarily viewed the models as decision support, that a low error margin (5–10 %) is expected, and that explainability is central to building trust towards the models. Neither model reached the level of acceptability described as clinically acceptable by the clinicians.

The conclusion is that machine learning has potential to support early identification of microvascular complications in patients with type 1 diabetes, but its practical usefulness is limited by class imbalance within the dataset and the clinical acceptability requirements.

Keywords: type 1 diabetes, T1D, microvascular complications, diabetic retinopathy, diabetic neuropathy, SVM-RBF, Random Forest, clinical acceptability, decision support, prediction, predictive analytics, machine learning

Förord

Detta examensarbete har en personlig betydelse för mig då jag själv lever med typ 1-diabetes. Arbetet har därför varit särskilt motiverande att genomföra, eftersom det berör ett område som är relevant för många andra diabetiker och jag vet hur skrämmande dessa komplikationer kan vara.

Jag vill rikta ett stort tack till alla respondenter som medverkade i intervjuerna och bidrog med värdefulla insikter som möjliggjorde studiens genomförande. Jag vill även ge ett stort tack till min handledare Christian Lennerholt och examinator Mikael Berndtsson för deras stöd och vägledning under arbetets gång.

INNEHÅLLSFÖRTECKNING

SAMMANFATTNING

ABSTRACT

FÖRORD

1	INLEDNING	1
2	BAKGRUNDSKAPITEL	2
2.1	Artificiell intelligens	2
2.1.1	Definition av artificiell intelligens	2
2.1.2	Artificiell intelligens appliceringsområden	2
2.2	Maskininlärning	3
2.2.1	Definition av maskininlärning	3
2.2.2	Applikationer av maskininlärning i praktiken	4
2.2.3	Kategorier av maskininlärning	4
2.2.4	Maskininlärningsalgoritmer	5
2.2.5	Modellutvärdering	6
2.3	Maskininlärning inom hälso- och sjukvård	7
2.4	Maskininlärning för prediktion av mikrovaskulära komplikationer	8
2.4.1	Klassificeringsalgoritmer för prediktion av komplikationer	9
2.5	Diabetes	9
2.5.1	Typ 1-diabetes (T1D)	10
2.5.2	Typ 2-diabetes (T2D)	10
2.5.3	Graviditetsdiabetes (GDM)	10
2.6	Mikrovaskulära komplikationer	10
2.6.1	Diabetisk retinopati	11
2.6.2	Diabetesnefropati	11
2.6.3	Diabetisk neuropati	11
2.7	Etiska utmaningar	12
3	PROBLEMOMRÅDE	13
3.1	Forskningsfråga	14
3.2	Avgränsningar	14
3.3	Förväntat resultat	15
4	METOD	16
4.1	Forskningsdesign	16
4.1.1	Experimentell utvärdering av maskininlärningsmodeller	16
4.1.2	Semi-strukturerade intervjuer med vårdpersonal för diabetes	17

4.1.3	Metodövervägande	18
4.2	Datainsamling	18
4.3	Bearbetning av data och analys	19
4.4	Forskningsetiska principer	20
5	MATERIALPRESENTATION OCH ANALYS	21
5.1	Datamaterialets omfattning	21
5.2	Bearbetning av utfallsvariabler	22
5.3	Bearbetning av inmatningsvariabler	23
5.4	Modell 1: SVM-RBF	24
5.4.1	Prediktiv prestanda för retinopati	25
5.4.2	Prediktiv prestanda för neuropati	25
5.5	Modell 2: Random Forest	26
5.5.1	Prediktiv prestanda för retinopati	27
5.5.2	Prediktiv prestanda för neuropati	28
5.6	Jämförelse mellan SVM-RBF och Random Forest	29
5.7	Intervjuanalys	30
5.7.1	Klinisk bedömning och arbetsflöde	31
5.7.2	Krav för klinisk tillit till maskininlärning	31
5.7.3	Praktisk betydelse av missade och falska fall	32
5.7.4	Praktisk tillämpning av maskininlärning inom vården	33
5.8	Klinisk acceptans av SVM-RBF och Random Forest	33
6	RESULTAT	36
6.1	Modellernas prediktiva prestanda	36
6.2	Acceptanskriterier för prediktiva modeller	37
6.3	Sammanfattande slutsats av modellernas kliniska acceptans	38
7	DISKUSSION	40
7.1	Vetenskapligt bidrag och reflektion	40
7.2	Metodreflektion	40
7.3	Samhälleliga och etiska aspekter	41
7.4	Förslag till fortsatt forskning	41
	REFERENSER	42

1 Inledning

Diabetes är en global kronisk sjukdom med betydande individuella och samhälleliga kostnader. Patienter med diabetes löper risk för att utveckla mikrovaskulära komplikationer, såsom diabetisk retinopati, nefropati och neuropati (Lu et al., 2023; Singh et al., 2025). Tidig upptäckt av dessa komplikationer är avgörande för att förbättra diabetikers liv för att minska nervskada, synnedbrettning och njursvikt (Lu et al., 2023). Samtidigt har den ökade tillgången till hälsodata öppnat möjligheten till att förutsäga om en patient ligger inom riskzon för komplikationer med hjälp av maskininlärning, där prediktiva modeller lär sig genom mönster i data och utför prediktioner (Kapa et al., 2024; Sarker, 2021).

Trots antalet diabetiker världen över ligger fokuset för prediktion av dessa mikrovaskulära komplikationer ofta hos typ 2-diabetiker (Du et al., 2025; Li et al., 2025). Antalet typ 1-diabetiker globalt beräknas vara 9,5 miljoner personer, samt över 500 000 nya fall av typ 1-diabetes beräknades under 2025 (Ogle et al., 2025). Eftersom andelen typ 1-diabetiker globalt är signifikant finns det ett behov av att utveckla och utvärdera maskininlärningsmodeller för att identifiera dessa mikrovaskulära komplikationer.

Syftet med denna studie är att undersöka hur maskininlärningsmodeller kan användas för prediktion av mikrovaskulära komplikationer hos patienter med typ 1-diabetes, samt bedöma deras prestanda genom prestandamått såsom AUC, F1-score, recall, precision, missfrekvens och FP-frekvens (frekvensen av falskt positiva fall), men även genom acceptanskriterier från beslutsfattare. Studien kommer att identifiera features i det tillgängliga datasetet och dess prediktionsbidrag samt jämföra prestandan hos de utvalda klassificeringsalgoritmerna, SVM-RBF och RF. Därefter utförs semi-strukturerade intervjuer med vårdpersonal inom diabetesvården för att bedöma den praktiska acceptansen av att använda maskininlärning som ett beslutsstöd för identifiering av mikrovaskulära komplikationer.

Studien är strukturerad på följande sätt: bakgrund, problemområde, metod, materialpresentation och analys, resultat och avslutningsvis en diskussion.

Bakgrunden presenterar studiens centrala begrepp och definitioner, därefter introduceras problemområdet och forskningsfrågan tillsammans med avgränsningar och det förväntade resultatet. Metodkapitlet beskriver studiens forskningsdesign, datainsamling, behandling och analys av data samt etiska överväganden. Materialpresentation och analyskapitlet beskriver arbetets utförande samt resultatkapitlet presenterar modellernas prestanda, kliniska acceptans och en slutsats. Avslutningsvis diskuteras metodval, resultatet, vetenskapliga, samhälleliga och etiska aspekter samt förslag till vidare forskning.

2 Bakgrundskapitel

Detta kapitel ger en introduktion till artificiell intelligens med särskilt fokus på maskininlärning och hur det används inom hälso- och sjukvården, specifikt för prediktion av mikrovaskulära komplikationer vid diabetes. Utöver centrala begrepp och definitioner introduceras vanliga maskininlärningsmetoder, såsom övervakad, oövervakad, semi-övervakad och förstärkningsinlärning, samt relevanta algoritmer för maskininlärning. Avslutningsvis beskrivs de olika etiska utmaningar som kan uppstå vid implementation av prediktiva modeller inom en klinisk praxis.

2.1 Artificiell intelligens

Mukhamediev et al. (2022) beskriver artificiell intelligens (AI) som möjligheten att utföra uppgifter som ofta förknippas med mänsklig intelligens med hjälp av en eller flera datorer. Den intellektuella delen av AI är inte en teknologi utan snarare en metodik där metoderna bakom AI är matematiska algoritmer som lär sig och justeras genom olika regler. AI använder sig av olika teknologier som exempelvis datorer vilket är ett krav för att möjliggöra användningen av AI, men den intellektuella komponenten är inte en del av teknologin. AI används däremot tillsammans med olika algoritmer, teknologier, system samt hårdvara för att utföra olika uppgifter (Emmert-Streib et al., 2020).

2.1.1 Definition av artificiell intelligens

Inom forskningen gällande AI finns det ännu ingen definition av intelligens och konsekvent har AI inte en etablerad definition. Flera studier formulerar egna definitioner av AI och anledningen till att AI inte har en etablerad definition beror delvis på att när begreppet "AI" används kan det referera till teknologi som smartphones (Emmert-Streib et al., 2020; Ofosu-Ampong, 2024).

Det som särskiljer AI från exempelvis smartphones är möjligheten till att anpassa sig till nya omständigheter, att lära sig från data och förbestämda regler samt resonera och fatta beslut för att utföra en uppgift (Mukhamediev et al., 2022; Ofosu-Ampong, 2024).

2.1.2 Artificiell intelligens appliceringsområden

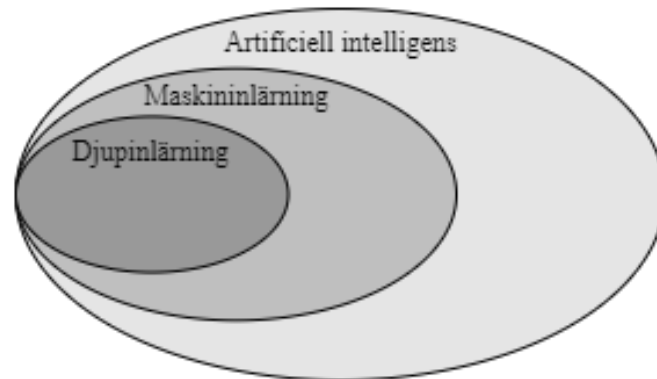
AI har en lång historik av användningsområden där AI redan användes på 1950-talet för att klassificera finansiella dokument, där AI föddes från idén att återskapa mänsklig intelligens digitalt (Li et al., 2023). Vanligt förekommande AI-tekniker inkluderar maskininlärning, neurala nätverk och djupinlärning som är en underkategori av maskininlärning. Inom finans används dessa AI-tekniker för att förstärka vinster, förminska risker och har även förmågan att upptäcka bedrägeri (Géron, 2019; Li et al., 2023).

Maskininlärning är en domän av artificiell intelligens och används för att utföra och lösa vetenskapliga problem och har flertal appliceringsområden. Exempel av appliceringsområden inkluderar upptäckt av kreditbedrägeri, hitta cancertumörer i

bildskanningar, summera långa dokument automatiskt och prognostisera inkomster baserat på historiska faktorer (Géron, 2019; Mukhamediev et al., 2022).

2.2 Maskininläring

Relationen mellan maskininläring (ML) och AI kan förklaras som att AI är det övergripande begreppet som innehåller flera olika underliggande domäner, där ML är en domän som tar upp en väsentlig del av det omfattande området AI och visualiseras i figur 1 (Pichler & Hartig, 2023).



Figur 1. Relationen mellan AI och Maskininläring figur inspirerad av Pichler & Hartig (2023).

Grunden till vad ML är beskrivs som datorer som lär sig från data, där programmet kan lära sig från data och anpassas utan att det programmeras för en specifik uppgift. Traditionellt sett programmeras regler för programmet, därefter utvärderas och anpassas programmet tills det uppnår en tillfredsställande nivå. ML kan användas vid mer komplexa uppgifter där klassisk programmering och regler inte är tillräckliga, exempelvis i en miljö som uppdateras snabbt och ofta, som ett spamfilter för e-post (Géron, 2019). I grunden består ML av olika algoritmer som kan justeras mot träningsdata och därefter användas mot ny data för att utföra prediktioner (Pichler & Hartig, 2023).

Pichler & Hartig (2023) beskriver att syftet med ML är att bygga en bra prediktiv modell, där "bra" innebär att modellen inte ska misslyckas med att utföra en prediktion när ny data introduceras till modellen, och att modellen generaliserar väl till nya miljöer.

2.2.1 Definition av maskininläring

Både Sarker (2021) och Géron (2019) definierar maskininläring som möjligheten att få ett system eller program att lära sig från erfarenhet eller data, för att uppdatera och justera sig automatiskt utan traditionella former av programmering.

Vidare beskriver Géron (2019) även en mer teknisk definition av maskininläring som att ett "datorprogram sägs lära sig av erfarenhet E med avseende på viss uppgift T och visst prestanda mått P , om dess prestanda på T , mätt med P , förbättras med erfarenhet E ".

2.2.2 Applikationer av maskininlärning i praktiken

I dagens samhälle finns det data överallt, nästan allting är uppkopplat till en datakälla där informationen sparas, exempelvis är data från sociala medier och hälsodata mycket vanligt. Denna data används för att träna ML-modeller och ML växer snabbt inom flera branscher (Sarker, 2021).

Ett vanligt område där ML används är inom hälso- och sjukvårdsbranschen. Prediktiv analys inom sjukvården är en väsentlig faktor till att förbättra och rädda patienters liv. Eftersom sjukdomar kan utvecklas snabbt och sjukvårdspersonal har begränsad tid ger ML ett signifikant stöd till personalen för att diagnostisera patienter. Det är särskilt viktigt att prediktioner är tillförlitliga, eftersom en felaktig diagnos kan försämra patienthälsa eller innebära allvarliga risker (Badawy et al., 2023).

Inom klinisk praxis används även ML-algoritmer för att diagnostisera bröstcancer där en tidig diagnos kan betyda skillnaden mellan att en patient går i remission eller avlider (Ganesan et al., 2025). I en ny översikt över bröstcancer upptäckt med hjälp av ML beskriver Ganesan et al. (2025) att ML har en möjlighet att förändra hur bröstcancer hanteras i sjukvården. Vidare har det visat sig inom forskning att det finns en hög potential för att identifiera och diagnostisera bröstcancer med vissa algoritmer, men att det finns en oro för partiskhet i dataset.

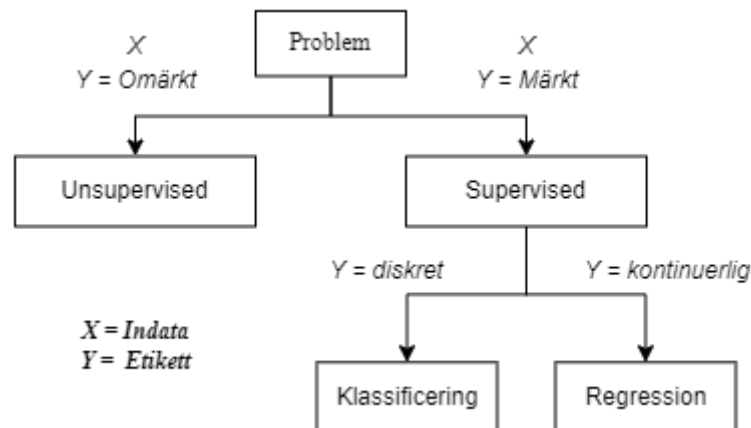
2.2.3 Kategorier av maskininlärning

Maskininlärningsmetoder och system kan delas in i olika kategorier beroende på vad syftet med modellen och algoritmen är. Eftersom det finns ett stort antal problem är det viktigt att välja korrekt metod för den uppgift som ML-modellen är tänkt att utföra (Géron, 2019; Mukhamediev et al., 2022). Det problem som efterfrågas att lösas med en ML-modell bygger på algoritmer som utvecklas och anpassas för det specifika problemet, och därmed motiveras valet av algoritm utifrån problemet (Géron, 2019).

Unsupervised Learning (UL) är en metod som använder algoritmer för att undersöka och hitta mönster i data utan någon övervakning vid analysen av data. Syftet är att identifiera underliggande strukturer, komponenter och kluster i dataset där kluster algoritmer som K-Means används vid oövervakad inlärning (Géron, 2019; Jiang et al., 2020). Denna metod kan exempelvis användas för kategorisering vid mental hälsa för att identifiera underliggande mönster och kategorisera dem via kluster (Jiang et al., 2020).

Supervised Learning (SL) är en metod som ofta används vid regression eller klassificeringsproblem (Géron, 2019). Vid övervakad inlärning tränas modellerna på data som är etiketterad för att klassificera ett specifikt resultat. Det krävs att data som används för att träna en klassificerings eller regressionsmodell har dessa etiketter för att möjliggöra validering av resultaten (Géron, 2019). För problem med kategoriskt utfall, som prediktion om en patient har en mikrovaskulär komplikation eller ej, används klassificeringsalgoritmer. För problem som har kontinuerliga utfall, som förutsägelse av

priser för hus i ett specifikt område, används istället regressionsalgoritmer, dessa typer visualiseras i figur 2 (Géron, 2019; Jiang et al., 2020; Maniruzzaman et al., 2021).



Figur 2. Beslutsträd för val av inlärningsmetod för olika problem inspirerad av Pichler & Hartig (2023).

Semi-Supervised Learning (SSL) metoden försöker att kombinera UL och SL metoderna för att förbättra prestandan hos modellerna, samt för att hantera problem som omärkt data genom att märka data med klassificerande information (Eckardt et al., 2022; van Engelen & Hoos, 2020). SSL har även möjligheten att användas vid problem där UL traditionellt sett används, exempelvis kan en kluster algoritm använda sig av SSL där kännedom av att viss data tillhör ett specifikt kluster kan vara förmånligt (van Engelen & Hoos, 2020). Ett praktiskt exempel av SSL är att träna en modell där endast delvis data har definierade etiketter, här används SSL algoritmen för att själv markera den omärkta datan med etiketter. Det nya märkta datasetet kan därefter användas för att träna en klassificeringsalgoritm liknande SL (Eckardt et al., 2022).

Reinforcement Learning (RL) skiljer sig signifikant från UL, SL och SSL där RL interagerar med sin omgivning för att lära sig (Panzer & Bender, 2022). RL är en flexibel metod som utnyttjar upprepade och varierande försök för att utföra en uppgift och lär sig från varje försök. På detta sätt tar RL bort behovet av fördefinierad märkt och omärkt data (Panzer & Bender, 2022). RL utvecklar gradvis en policy vilket definierar vad RL-modellens nästa handling kommer att vara. Ett exempel där en RL-algoritm tillämpades är när RL användes för att vinna mot världsmästaren Ke Jie i en Go match. I detta exempel spelade och analyserade RL-algoritmen miljontals matcher för att utveckla dess policy som i sin tur vann matchen mot Ke Jie (Géron, 2019; Panzer & Bender, 2022).

2.2.4 Maskininlärningsalgoritmer

Prediktiva modeller använder sig av diverse maskininlärningsalgoritmer för att möjliggöra en prediktion baserat på data (Badawy et al., 2023).

Support Vector Machine (SVM) är både en mångsidig och kraftfull algoritm som kan utföra både linjär och icke-linjär klassificering och regression (Géron, 2019). En SVM-modell kan använda sig av olika kärnor som en linjär kärna eller en icke-linjär kärna, exempelvis Gaussian RBF kärnan (SVM-RBF) (Maniruzzaman et al., 2021).


Logistic Regression (LR) fungerar ofta bra på mindre dataset och ger en linjär separation av klasserna (Badawy et al., 2023). Resultatet från en LR-modell tolkas som en sannolikhet att en variabel tillhör en specifik binär klass, exempelvis sannolikheten att ett e-postmeddelande är spam. Eftersom algoritmen är binär kan endast två klasser utdelas vid klassificeringen och om sannolikheten är över 50 % tilldelas den positiva klassen, samt vid en sannolikhet under 50 % tilldelas den negativa klassen (Badawy et al., 2023; Géron, 2019).

Random forest (RF) är en ensemblemetod som bygger på flera beslutsträd för att utföra prediktioner (Fife & D’Onofrio, 2023). En RF-modell använder sig av slumpmässigt valda features för att öka algoritmens trädvariation, vilket i sin tur leder till en generellt sett bättre presterande modell. Fördelen med en ensemble algoritm som RF är att den generaliserar sig enkelt mot ny data och förhåller sig bra vid stora dataset (Badawy et al., 2023; Fife & D’Onofrio, 2023).

2.2.5 Modellutvärdering

En maskininlärningsmodell prestanda kvantifieras och utvärderas genom följande mått: noggrannhet (andelen korrekta prediktioner), precision, recall, arean under kurvan (AUC) och F1-score (Géron, 2019).

Precision baseras på antalet sanna positiva prediktioner som divideras med det sammanlagda värdet av både sanna och falska positiva prediktioner (Géron, 2019). Exempel visas i figur 3 nedan:



Figur 3. Exempel av precision kalkylering inspirerad av Géron (2019).

Recall är andelen sanna positiva fall som upptäcks av maskininlärningsalgoritmen och tar de sanna positiva (TP) prediktionerna och dividerar dem med antalet sanna positiva (TP) och falska negativa prediktionerna (FN) (Géron, 2019). Recall används ofta tillsammans med precision för att bättre utvärdera en modells prestanda som skapar F1-score (Géron, 2019).

F1-score är det harmoniska medelvärdet av precision och recall och utvärderar prestandan av en modell genom följande ekvation (Géron, 2019):

$$F1 = \frac{TP}{TP + \frac{FN + FP}{2}}$$

F1-score ekvationen leder till en bättre utvärdering av modeller genom att kombinera både precision och recall, för att en modell ska uppnå ett högt F1-score behöver modellen prestera högt i både precision samt recall (Géron, 2019).

Mottagaroperatörskurva (ROC-kurva) används vid klassificeringsalgoritmer som är binära (Géron, 2019). ROC-kurvan avbildar andelen TP mot de falska positiva (FP) mot varandra, för att jämföra olika klassificeringsalgoritmer kan AUC beräkna arean under ROC-kurvan. En perfekt klassificeringsmodell har ROC AUC = 1, medan en helt slumpmässig modell har ROC AUC = 0,5 (Géron, 2019).

Maskininlärning är det praktiska verktyget som används för att bygga prediktiva modeller och dess prediktiva förmåga beror på träningsdata och korrekt algoritmval. I detta arbete kommer olika algoritmer utvärderas och jämföras med hjälp av denna teoretiska bakgrund för att förstärka algoritmvalet och utvärderingsmått.

2.3 Maskininlärning inom hälso- och sjukvård

Maskininlärning inom hälso- och sjukvårdsbranschen har blivit allt mer populärt med det ökande behovet av mer personlig vård (Sukri et al., 2025). Det finns däremot flera utmaningar och risker med att använda maskininlärning för sjukvårdsprognostisering (Badawy et al., 2023; Sukri et al., 2025). Även om ML har fått en ökad uppmärksamhet inom hälso- och sjukvården finns det fortfarande en osäkerhet bland hur ML kan användas för att förbättra beslutsfattandet inom för diagnostik då tillämpningen av ML inom klinisk praxis är begränsad (Li et al., 2025).

Ofta används klassificeringsmetoder inom hälso- och sjukvårdsbranschen för att klassificera kategoriskt data. Patienter klassificeras i olika kategorier, där ett exempel på kategori är om en patient befinner sig i en hög eller låg riskzon för cancer (Sukri et al., 2025). Vid medicinsk diagnostisering är det lämpligt att använda klassificeringsmetoder eftersom data ofta är kategoriserad, exempelvis om en patient utvecklat komplikationen nefropati eller ej (Maniruzzaman et al., 2021; Sukri et al., 2025). Det som matas in i modellen är den omringande informationen även kallat features som bestämmer om en patient har nefropati eller ej, exempel av features inkluderar HbA1c, BMI eller diabetesduration (Du et al., 2025; Maniruzzaman et al., 2021).

Användningen av maskininlärning inom hälso- och sjukvårdsbranschen skiljer sig från andra branscher eftersom riskerna är höga när något går fel eller en prediktion är felaktig (Badawy et al., 2023). Patienters liv kan hamna i fara om en modell felaktigt förutser att en patient befinner sig i riskzon eller ej (Badawy et al., 2023).

Badawy et al. (2023) och Habehh & Gohel (2021) betonar vikten av att en maskininlärningsmodell ger en korrekt prediktion vid diagnostisering av patienter och nämner konsekvenserna vid en felaktig prediktion. Sukri et al. (2025) argumenterar att det som gör en modell pålitlig och förbättrar noggrannheten vid prediktioner är urvalet och kvalitén av features.

Några identifierade utmaningar med maskininlärning inom hälso- och sjukvårdsbranschen inkluderar (Habeheh & Gohel, 2021):

- Felaktig diagnostisering vid prediktion och dess konsekvenser.
- Sårbarheter i systemet och integriteten.
- Tolkning och tillämpbarhet av resultat samt datatillgänglighet för reproducerbara resultat.

Implementation av maskininlärning inom hälso- och sjukvårdsbranschen kan därmed vara svårt med dessa utmaningar i åtanke (Habeheh & Gohel, 2021).

För att lösa felaktig diagnostisering rekommenderar Habeheh & Gohel (2021) att modellerna har sjukvårdspersonal som utför löpande tillsyn då en felaktig diagnos kan ge svåra konsekvenser, exempelvis vid diagnos av depression eller bröstcancer, för att minska risken av falska positiva och negativa diagnoser.

Hälsodata är i sin natur känslig och innehåller personlig information om patienter, samt kräver maskininlärnings modeller en enorm mängd med data för att effektivt tränas och uppdateras för att utföra prediktioner (Habeheh & Gohel, 2021). Integritet blir därmed en utmaning eftersom data ofta lagras i molnet och därmed bör ansvarsskyldighet över hälsodatan övervägas innan utvecklingen påbörjas (Habeheh & Gohel, 2021).

Eftersom sjukvårdspersonal har en begränsad mängd tid för varje besök kan diagnostisering av en patient bli en stressig och svår process (Badawy et al., 2023; Habeheh & Gohel, 2021). Samtidigt är det viktigt att diagnosen är korrekt, men i en undersökning visade det sig att 56 % av läkare gav varje patient mindre än 16 minuter per besök. ML modeller kan användas för att underlätta för läkare genom att agera som ett beslutsstöd och ge patienter mer tid vid läkarbesök, vilket i sin tur förbättrar precisionen av diagnostisering, resultat och patienters liv (Badawy et al., 2023; Habeheh & Gohel, 2021).

2.4 Maskininlärning för prediktion av mikrovaskulära komplikationer

Prediktion för mikrovaskulära komplikationer möjliggörs med hjälp av hälsodata som patientjournaler och retinabilder för diabetisk retinopati (Kanbour et al., 2024). Valet av modell och algoritm beror ofta på vad för data som finns tillgänglig men ofta är övervakad inlärning vanlig vid prediktion av mikrovaskulära komplikationer (Kanbour et al., 2024).

Valet av features eller inmatningsvariabler spelar en viktig roll i att skapa en modell som ger ett trovärdigt resultat (Géron, 2019). De mest vanliga inmatningsvariablerna vid prediktion av mikrovaskulära komplikationer inkluderar HbA1c, diabetesduration, BMI, LDL-C, högdensitetslipoproteinkolesterol (HDL-C) och serum kreatinin (Scr) (Du et al., 2025; Kanbour et al., 2024).

2.4.1 Klassificeringsalgoritmer för prediktion av komplikationer

Klassificeringsalgoritmer är det vanligaste bland studier som använder maskininlärning för att prediktivt diagnostisera mikrovaskulära komplikationer hos patienter (Du et al., 2025; Kanbour et al., 2024; Maniruzzaman et al., 2021).

SVM-RBF algoritmen har visat sig vara en konkurrenskraftig algoritm för att specifikt identifiera diabetesnefropati (Maniruzzaman et al., 2021). Algoritmen visade sig prestera bättre än andra klassificeringsalgoritmer som LR, Naive Bayes (NB) och K-Nearest neighbor (KNN) med en noggrannhet på 88,7 % och 0,91 AUC.

RF-algoritmen har visat en hög prestanda i studier för prediktion av diabetesnefropati hos typ 2-diabetiker (Li et al., 2025). I översikten av Li et al. (2025) visade resultatet att modeller som utnyttjade RF algoritmen hade ett AUC värde på 0,848 med ett 95 %-igt konfidensintervall på 0,785–0,911.

I en klinisk miljö kan tolkningsbarheten av ML-modeller ses som svårt och Dagliati et al. (2018) nämner att SVM och RF-modeller har generellt ett högre AUC värde men en lägre tolkningsbarhet jämfört med LR-modeller. Valet av algoritm för att prediktera mikrovaskulära komplikationer hamnar då mellan tolkningsbarheten och tillämpbarheten samt prestandan av modellen (Dagliati et al., 2018).

Användningen av ML inom hälso- och sjukvården kan förbättra diagnostik och effektiviteten, men det krävs en noggrann integration och en ML-modell med hög prediktiv förmåga för att undvika felaktig diagnos. Eftersom en korrekt diagnos är väsentligt vid ML inom sjukvården kommer studien att fokusera på att uppnå en hög prestanda vid implementation av algoritmerna.

2.5 Diabetes

Diabetes är en sjukdom som kännetecknas av långvarig hyperglykemi som uppstår på grund av nedsatt funktion av β -celler eller total förgörelse av β -celler (Singh et al., 2025). Enligt data från Världshälsoorganisationen (WHO) är diabetes en av de främsta dödsorsakerna i världen och en tidig diagnos är ytterst viktigt för att minska sannolikheten för komplikationer (Quattrin et al., 2023; Singh et al., 2025). Här kan maskininlärning hjälpa minska detta nummer genom att erbjuda en möjlighet till prediktiv analys av hälsodata för tidig identifiering av sjukdom eller komplikationer (Badawy et al., 2023; Sukri et al., 2025).

I en uppskattning av den internationella diabetesfederationen förväntas det att antalet patienter med diabetes kommer att öka till 783 miljoner personer år 2045 (Singh et al., 2025). Det nämns även i översikten av Singh et al. (2025) att en av tre patienter feldiagnosteras vid diagnostisering av diabetes vilket kan leda till en felaktig representation av antalet diabetiker globalt.

Vanliga symtom hos diabetiker inkluderar men är inte begränsade till: minskad mättnadskänsla, ökad trötthet, sår som inte läker, ökad törst, frekvent urinering och viktökning (Singh et al., 2025).

2.5.1 Typ 1-diabetes (T1D)

Patienter med typ 1-diabetes lever med en kronisk autoimmun sjukdom och är en av de vanligaste kroniska sjukdomarna hos ungdomar och barn (Quattrin et al., 2023; Singh et al., 2025). En patient med typ 1-diabetes producerar defekta antikroppar som attackerar och förstör β -celler vilket leder till komplett insulinbrist hos patienten. Patienter med typ 1-diabetes kräver därmed en extern källa av insulin för att överleva (Quattrin et al., 2023; Singh et al., 2025). Typ 1-diabetes innebär en livslång sjukdom med risker till både mikrovaskulära och makrovaskulära komplikationer, men det har också visats att ytterligare autoimmuna sjukdomar uppstår oftare hos typ 1-diabetiker (Quattrin et al., 2023).

2.5.2 Typ 2-diabetes (T2D)

Till skillnad från typ 1-diabetes är typ 2-diabetes varken kronisk eller autoimmun och är i stället primärt en metabolisk sjukdom (Singh et al., 2025). Patienter med typ 2-diabetes har en nedsatt funktion av β -celler vilket leder till försämrad produktion av insulin och kräver inte alltid en extern källa av insulin (Singh et al., 2025).

Typ 2-diabetes utvecklas generellt sett i äldre personer och det uppskattas att 90 % av alla diabetiker är typ 2-diabetiker (Singh et al., 2025). Typ 2-diabetes orsakas ofta av ohälsosamma vanor vilket kan leda till dödliga mikro- och makrokomplikationer som strokes eller hjärtsjukdomar (Singh et al., 2025).

2.5.3 Graviditetsdiabetes (GDM)

Graviditetsdiabetes är ett tillstånd som orsakar att gravida kvinnor utvecklar glukosintolerans och drabbar ungefär 10 % av alla gravida kvinnor (Singh et al., 2025). Placentahormoner kan orsaka insulinresistens hos dessa kvinnor och det uppskattas att 50 % av kvinnor med graviditetsdiabetes löper risk till att utveckla typ 2-diabetes (Singh et al., 2025).

2.6 Mikrovaskulära komplikationer

Desto längre en patient har haft diabetes ökar risken till att utveckla diverse mikro- och makrovaskulära komplikationer (Lu et al., 2023). Mikrovaskulära komplikationer hos diabetiker är en stor del av varför diabetes klassificeras som ett av de största dödsorsakerna i världen (Lu et al., 2023; Singh et al., 2025). Mikrovaskulära komplikationer orsakar även försämrad livskvalité som nedsatt syn eller nervskada. Det betonas att det är ytterst viktigt att dessa komplikationer upptäcks tidigt för att minska dödsfall och förbättra diabetikers livskvalité (Lu et al., 2023; Quattrin et al., 2023).

2.6.1 Diabetisk retinopati

Diabetisk retinopati är en mikrovaskulär komplikation som hotar diabetikers syn och uppskattas förekomma hos 34.6 % av diabetiker (Lu et al., 2023). Diabetisk retinopati orsakar en uppskattad 10 000 nya fall av blindhet årligen och sker främst hos den äldre populationen (Lu et al., 2023).

Utvecklingen av synförlust och blindhet på grund av diabetisk retinopati har även sett en signifikant ökning, där utvecklingen av diabetisk retinopati har en stark korrelation med diabetesduration (Lu et al., 2023). För att minska risken för nedsatt syn eller blindhet nämner Lu et al. (2023) vikten av att det glykerade hemoglobinet (HbA1c) håller en stabil nivå, samt att vid en tidig upptäckt kan uppåt 98 % av diabetesrelaterad synskada förhindras.

2.6.2 Diabetesnefropati

Diabetesnefropati, även kallat diabetisk njursjukdom, är den främsta orsaken till njursvikt och nedsatt njurfunktion och har en hög prevalens hos diabetespatienter (Maniruzzaman et al., 2021).

En uppskattad prevalens av diabetesnefropati är runt 30 % hos typ 1-diabetiker medan prevalensen hos typ 2-diabetiker ligger mellan 25–40 %. Komplikationen har inte visat sig minska, och istället visar ett ökat antal fall, vilket konsekvent har ökat dödsantalet på grund av diabetesnefropati (Lu et al., 2023; Maniruzzaman et al., 2021).

Liknande diabetisk retinopati är en stabil nivå av HbA1c väsentligt för att minska risken att utveckla diabetesnefropati. Vikten av tidig upptäckt betonas även som en viktig del i att förhindra utvecklingen av diabetesnefropati och dess associerande sjukdomar (Lu et al., 2023; Maniruzzaman et al., 2021).

2.6.3 Diabetisk neuropati

Diabetisk neuropati är en komplikation som har varierande symtom som exempelvis nedsatt känsel, hjärtproblem eller magproblem (Lu et al., 2023). Diabetiker som har haft diabetes under en längre tid löper större risk för att utveckla diabetisk neuropati. Detta stöds av Partanen et al. (1995) studie där 8,7 % av patienterna hade diabetisk neuropati och efter 10 år ökades prevalensen av diabetisk neuropati hos dessa patienter till 41,9 %.

Patienter som utvecklats nervskada på grund av diabetisk neuropati har ännu inte tillgång till någon behandling som kan mildra eller reparera smärtan orsakad av skadan (Lu et al., 2023). Komplikationen kan resultera i amputation, och överlevnaden för patienter efter en amputation på grund av diabetisk neuropati är låg. Därför är tidig upptäckt av mikrovaskulära komplikationer som diabetisk neuropati viktigt för att öka patienters livskvalité och livslängd (Lu et al., 2023).

Det som diabetisk neuropati har gemensamt med diabetes retinopati och diabetesnefropati är vikten av ett stabilt HbA1c (Lu et al., 2023). Andra riskfaktorer för

att utveckla diabetisk neuropati är exempelvis lågdensitetslipoprotein kolesterol (LDL-C) och kroppsvikt (BMI) (Du et al., 2025; Lu et al., 2023).

2.7 Etiska utmaningar

En stor utmaning vid implementering av prediktiva maskininlärningsmodeller är de etiska frågorna som uppstår (Grote & Berens, 2020). Det finns även tvivel av praktisk tillämpbarhet och tolkning av diagnostisering utförd av ML-modeller i praktiken samt oro av en minskad relation mellan patient och läkare (Grote & Berens, 2020; Habehh & Gohel, 2021).

Tillämpningen av maskininlärningsalgoritmer utgör en risk inom hälso- och sjukvården där snarare än att öka kvalitén av beslut kan sjukvårdspersonal främja defensiv medicin, för att minimera potentiella risker från feldiagnostisering (Grote & Berens, 2020). Exempelvis om en vårdgivare och ML-modell ger två olika diagnoser till en patient är det oklart vem som är korrekt. I det fall att modellen är svårtolkad är det inte säkert att vårdgivaren kan förstå beslutet eller hur ML-modellen kom fram till sin diagnos, vilket kan medföra skepticism mot beslutet (Grote & Berens, 2020). I det fall att vårdgivaren ignorerar ML-modellens beslut och går efter sin egen diagnos och diagnosen är felaktig kan det leda till stora konsekvenser för vårdgivaren. Om i stället vårdgivaren bestämmer sig för att följa ML-modellens diagnos och den är inkorrekt kan även detta leda till konsekvenser för vårdgivaren (Grote & Berens, 2020).

Studier visar även att partiskhet i träningsdata är ett problem där ML-modeller kan missgynna vissa etniska minoriteter (Grote & Berens, 2020). Ett exempel som Grote & Berens (2020) nämner är att en ML-modell kan ha en sämre förmåga att korrekt prediktera hudsjukdomar hos patienter med en mörkare hudton i jämförelse med patienter med en ljusare hudton. För att undvika bias bör modeller tränas och valideras på data med en tillräcklig demografisk mångfald, däremot kan det visa sig svårt eftersom hälsodata ofta är begränsad på grund av deras känsliga innehåll (Grote & Berens, 2020).

Utveckling och implementationen av ML-modeller inom hälso- och sjukvården kan stöta på flertal etiska utmaningar, exempelvis felaktiga beslut eller partiskhet i data. Studien kommer därför att överväga dessa etiska utmaningar och undvika klassiska etiska fallgropar vid utvecklingen av ML-modellerna.

3 Problemområde

Artificiell intelligens, prediktiva modeller och prediktiv analys är ett växande område inom sjukvården för att identifiera patienter med risk för sjukdom genom mönster i patientdata (Badawy et al., 2023). Maskininlärning och prediktiva modeller används idag för att förutse sjukdomar eller komplikationer hos patienter, exempelvis genom klinisk data. Precisionen av dessa prediktiva modeller är väsentlig för patienters liv där en träffsäker modell som diagnostiserar en patient med en sjukdom som är svåråtgångad av människor kan rädda en patients liv. Däremot kan en inkorrekt förutsägelse få motsatt effekt och i stället sätta patientens liv i fara (Badawy et al., 2023).

Vidare har forskning visat att klassificeringsmodeller som Support Vector Machine (SVM) metoden med Radial Basis Function (RBF) kärnan (SVM-RBF) och Random Forest (RF) har en lovande prestanda för att analysera och förutsäga den mikrovaskulära komplikationen nefropati hos typ 2-diabetiker (Li et al., 2025; Maniruzzaman et al., 2021). RF och SVM-RBF visade höga prestandamått, där RF visade en AUC på 0,848 samt SVM-RBF modellen visade en AUC på 0,91, detta tyder på att modellerna har en hög prediktiv förmåga (Li et al., 2025; Maniruzzaman et al., 2021). Vidare beskriver Li et al. (2025) hur RF kan användas som ett värdefullt stöd vid kliniskt beslutsfattande, och hur integration av ML inom klinisk praxis, tillsammans med medicinska experter som läkare, kan effektivisera och förbättra läkares beslutsfattande, samtidigt som det ökar patienters livskvalitet eftersom komplikationer kan upptäckas tidigare.

Utöver dessa klassificeringsmodeller rapporterade Du et al. (2025) i deras studie en XGBoost-modell som hade en god prestanda med AUC på 0,83 för att prediktera risken för att utveckla nefropati. Studien identifierade även relevanta features för prediktion, som exempelvis nivån av glykerat hemoglobin (HbA1c) hos patienten, som även används i studien av Dagliati et al. (2018).

Typ 1-diabetes (T1D) är en kronisk autoimmun sjukdom och patienter som lever med T1D har en livslång risk för att utveckla de tre olika mikrovaskulära komplikationerna, vilket inkluderar nefropati, retinopati och neuropati (Quattrin et al., 2023). I sin studie nämner även Quattrin et al. (2023) att en tidig identifiering av dessa mikrovaskulära komplikationer hos typ 1-diabetespatienter kan leda till mildrad skada orsakad av dessa komplikationer.

Trots att T1D har flera komplikationer fokuserar många studier enbart på en av komplikationerna där nefropati är vanligast bland studierna, i studien av Li et al. (2025) granskades 26 studier om prediktiva modeller för diabetes nefropati hos typ 2-diabetiker. I studien av Quattrin et al. (2023) nämns de tre olika komplikationerna nefropati, retinopati samt neuropati, däremot ligger ofta enbart en mikrovaskulär komplikation i fokus inom maskininlärnings studier. Dagliati et al. (2018) visade i deras studie en möjlighet till att fokusera på de tre olika mikrovaskulära komplikationerna, studien inkluderade endast typ 2-diabetiker och studerade olika tidpunkter från att patienten diagnostiserades med diabetes.

I studien av Du et al. (2025) nämner de att studier som använder maskininlärning och prediktiv analys för att prediktera mikrovaskulära komplikationer hos patienter med T1D är sällsynt, trots att det uppskattas vara 9,5 miljoner personer som lever med T1D globalt och över 500 000 nya fall av T1D beräknades för 2025 (Ogle et al., 2025). Fokus i studierna är att utvärdera modellernas prestanda genom prestandamått, och det finns ett forskningsgap kring hur acceptabla dessa prestandaresultat är i en klinisk kontext. Vidare saknas det även studier som jämför olika prediktiva modeller för att avgöra vilken modell som har högst träffsäkerhet och klinisk acceptans för att prediktera utveckling av retinopati och neuropati hos typ 1-diabetespatienter.

Studiens syfte är att fylla ett forskningsgap och besvara forskningsfrågan genom att testa och jämföra Random Forest (RF) och Support Vector Machine med RBF-kärna (SVM-RBF) på data från det Nationella Diabetesregistret (NDR) i Västra Götalandsregionen. Modellernas prestandamått (AUC, F1-score, precision, recall, missfrekvens och FP-frekvens) kommer att användas som exempel för att utreda dess acceptansnivån inom klinisk praxis. Resultaten diskuteras i de semi-strukturerade intervjuerna med vårdpersonal inom diabetesvården, där de får svara på modellernas praktiska användbarhet och deras kliniska relevans som beslutsstöd vid diagnostik av mikrovaskulära komplikationer hos typ 1-diabetiker. Resultatet från intervjuerna används även som underlag för att utvärdera modellernas acceptansnivå.

3.1 Forskningsfråga

Studiens syfte är att identifiera vilken av de utvalda prediktiva modellerna som har högst potential samt den kliniska acceptansen som beslutsstöd vid diagnostisering av mikrovaskulära komplikationer hos typ 1-diabetiker.

Det identifierade tomrummet i forskningen motiverar studiens forskningsfråga vilket lyder:

”Vilken prediktiv modell presterar bäst för att identifiera typ 1-diabetespatienter med risk att utveckla diabetisk retinopati och neuropati?”.

3.2 Avgränsningar

För att kunna undersöka vilka prediktiva modeller som bäst identifierar riskpatienter för diabetisk retinopati och neuropati, och därmed uppfylla studiens syfte, krävs vissa avgränsningar.

För att besvara den etablerade forskningsfrågan avgränsas data till enbart vuxna personer med typ 1-diabetes, detta innebär att barn inte ingår i studien eftersom mikrovaskulära komplikationer utvecklas över längre tid.

Studien inkluderar enbart patienter med retinopati, neuropati och patienter utan dokumenterad mikrovaskulär komplikation. Det innebär att patienter med diabetesnefropati inte inkluderas, denna begränsning beror på grund av den data som

samlades in från NDR inte innehåller information om diabetesnefropati eller nedsatt njurfunktion.

Valet av algoritmerna SVM-RBF och RF för att träna modellerna motiveras av deras etablerade prestanda i tidigare studier. Eftersom den etablerade forskningsfrågan är ett klassificeringsproblem och det tillgängliga datasetet är kategoriskt används enbart klassificeringsalgoritmer.

För att utvärdera modellernas acceptansnivå som beslutsstöd och hur modellerna kan användas i praktiken intervjuas enbart till beslutsfattare inom diabetesvården. Detta innebär att läkare eller sjuksköterskor utan erfarenhet av diabetes inte inkluderas i urvalet för intervjuerna, avgränsningen fastställs för att få in relevanta åsikter och kriterier om hur ML-modeller kan användas som beslutsstöd.

3.3 Förväntat resultat

Det förväntade resultatet med studien är att de valda modellerna som tränas på det tillgängliga datasetet kommer att identifiera och klassificera patienter som löper en risk till att utveckla diabetisk retinopati eller neuropati. Det antas att features som HbA1c, LDL-C, HDL-C, BMI och diabetesduration som har identifieras i tidigare studier kommer att användas som inmatningsvariabler för att prediktera risken till utvecklingen av både diabetisk retinopati och diabetisk neuropati (Du et al., 2025; Kanbour et al., 2024).

Vetenskapligt kan studien bidra till hur väl maskininlärning tillämpas vid prediktion av mikrovaskulära komplikationer hos typ 1-diabetiker, där det saknas forskning för typ 1-diabetiker. Resultatet förväntas ge ett underlag för framtida studier för potentiell vidare forskning och en möjlig framtida implementering av maskininlärning inom hälso- och sjukvårdsbranschen.

Beroende på hur mycket av datasetet från NDR kan användas vid träningen av de olika modellerna är det osäkert hur väl modellerna kommer att generalisera sig. Prestandan av modellerna är beroende på hur balansen ser ut i datasetet. Om de olika klasserna i datasetet är välbalanserat kan modellerna uppnå en hög prestanda, däremot om datasetet är obalanserat kan det resultera i en obalanserad prestanda vid klassificering och en lägre F1-score/AUC.

Beroende på resultaten från modellernas prestanda kan det ge olika resultat vid intervjuerna, då en hög prestanda kan ge beslutsfattare en högre tillförlitlighet att använda ML som ett beslutsstöd för diagnostisering i praktiken, medan en låg prestanda kan ge motsatt effekt. Därmed förväntas det att svaren från vårdpersonalen kan variera beroende på resultaten av modellerna. Det är även möjligt att ingen av modellerna når en tillfredsställande kliniskt acceptabel nivå, särskilt om modellerna visar en hög andel av patienter som missas eller identifieras felaktigt.

4 Metod

Detta kapitel beskriver metoden som användes för att genomföra studien och besvara den etablerade forskningsfrågan. Kapitlet introducerar studiens forskningsdesign och den övergripande metodansatsen. Kapitlet beskriver även studiens datainsamling och datakällor som användes, samt bearbetningen och analysen av data. Avslutningsvis beskrivs de forskningsetiska principer som studien följt under genomförandet.

4.1 Forskningsdesign

Studiens metod är inspirerad av en sekventiell förklarande mixed-methods-ansats som förklaras av Creswell (2014), där ansatsen är tvåfasig. Studien använder sig av kvantitativa experiment som genomförs i den första fasen, och därefter kompletteras studien med semi-strukturerade intervjuer. Syftet med det sekventiella upplägget är att använda intervjuerna för att förklara den kliniska acceptansen av ML som beslutsstöd utifrån de kvantitativa resultaten i den första fasen av studien.

4.1.1 Experimentell utvärdering av maskininlärningsmodeller

Studien har primärt en kvantitativ och experimentell ansats och syftar till att jämföra de utvalda modellernas prediktiva prestanda, med målet att identifiera vilken av modellerna som presterar bäst vid prediktion av mikrovaskulära komplikationer hos typ 1-diabetiker. Utöver den experimentella utvärderingen kompletteras studien med semi-strukturerade intervjuer, där beslutsfattare inom diabetesvården får besvara frågor om den kliniska acceptansen av ML som beslutsstöd och där acceptanskriterier identifieras.

Wohlin et al. (2012) beskriver att ett experiment används för att testa en teori eller hypotes genom att kontrollera vissa faktorer, som exempelvis variabler som kontrolleras, och därefter observera utfallet och dra slutsatser om sambandet mellan behandling och resultat. Ett experimentets primära funktion är att pröva hypoteser eller relationer där hypotesen formuleras innan utvärderingen (Wohlin et al., 2012).

I denna studie utgör modellvalet, SVM-RBF och Random Forest, de behandlingar som utförs, medan modellernas prestanda mäts genom AUC, F1-score, precision, recall, missfrekvens och FP-frekvens. De kliniska inmatningsvariabler från NDR register fungerar som det datamaterial som prediktionen bygger på, och experimentets syfte är att utvärdera vilken modell som ger bäst resultat för prediktion av diabetisk neuropati och diabetisk retinopati. I linje med Wohlin et al. (2012) används därmed modellernas resultat för att besvara vilken modell som presterar bäst genom prestandamått.

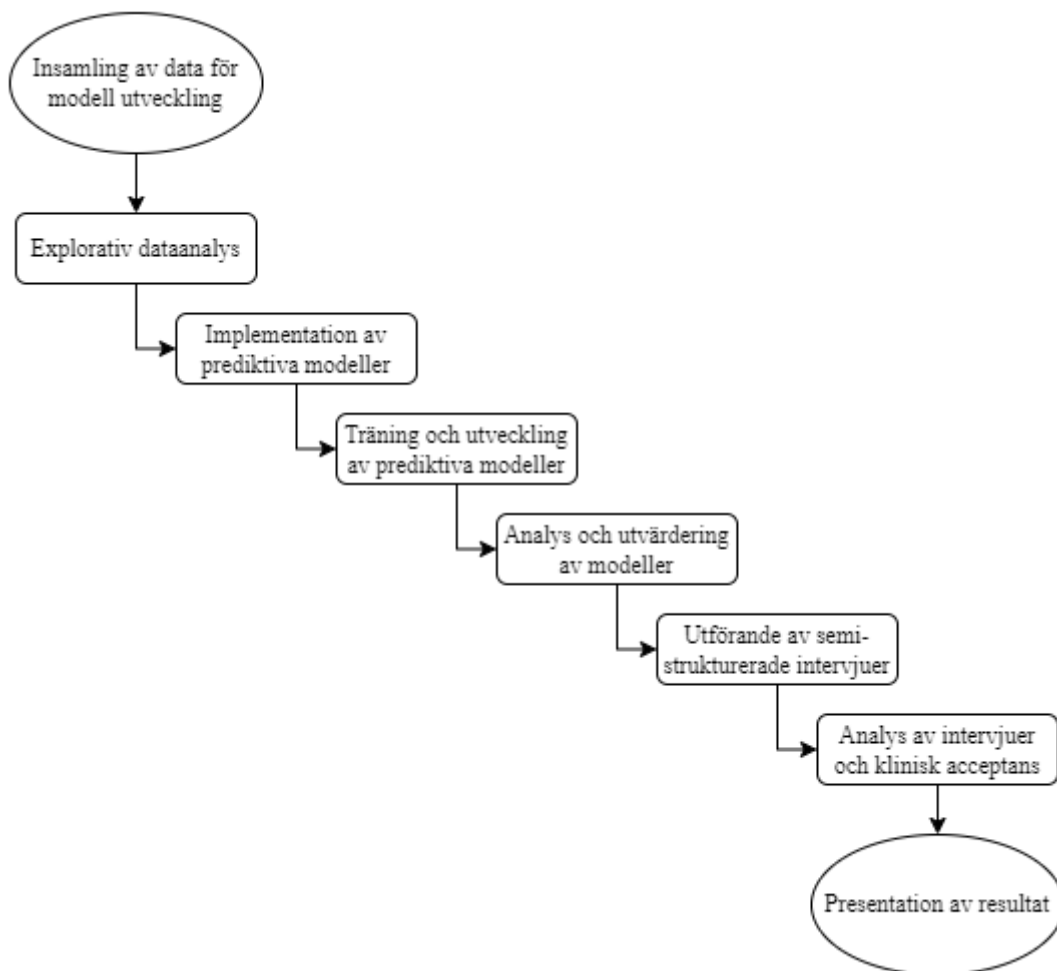
Studiens urval av maskininlärningsalgoritmer har baserats på tidigare dokumenterad prestanda inom prediktion för mikrovaskulära komplikationer. Géron (2019) rekommenderar att använda klassificeringsalgoritmer när data är kategoriskt och etiketterad vilket ytterligare motiverar valet av SVM-RBF och RF-algoritmerna.

4.1.2 Semi-strukturerade intervjuer med vårdpersonal för diabetes

Efter den kvantitativa prestandautvärderingen genomförs semi-strukturerade intervjuer som riktar mot relevanta intressenter, vilket inkluderar vårdpersonal inom diabetesvården, som kan dra nytta av de utvecklade modellerna. Intervjuerna syftar till att undersöka beslutsfattarens uppfattning om modellernas kliniska acceptans, dess tillförlitlighet och potentiella implementationshinder inom en klinisk praxis. Intervjuerna baseras på strukturerade frågor men är öppna för följdfrågor för att fånga mer nyanserade perspektiv av ML som beslutsstöd för diagnostik av mikrovaskulära komplikationer och acceptanskriterier.

Jämförelsen av de prediktiva modellerna och intervjuerna ger en insikt om vilken prediktiv modell som är lämpligast för analys av hälsodata inom diabetesvården.

För att besvara studiens etablerade forskningsfråga följer studien följande flöde, se figur 4:



Figur 4. Studiens övergripande metodflöde.

4.1.3 Metodöverbäggande

En alternativ metod hade varit att enbart genomföra den experimentella delen av studien och utelämma de semi-strukturerade intervjuerna med vårdpersonalen. En sådan ansats hade enbart fokuserat på modellernas tekniska prestanda och besvarat vilken av modellerna som presterar bäst utifrån prestandamåttten. Däremot hade en sådan metod lämnat studien utan en klinisk vy av modellerna som ett beslutsstöd, vilket innebär att modellerna inte hade haft en möjlighet att utvärderas i relation till kliniska acceptanskriterier. Eftersom studiens syfte även omfattar klinisk acceptans hade därmed ett enbart kvantitativt upplägg inte varit tillräckligt för att besvara forskningsfrågan.

Ett alternativ för intervjuerna hade varit att använda enkäter för att identifiera den kliniska acceptansen av modellerna. En enkät hade möjligtvis kunnat nå fler respondenter, men hade däremot gett ett mindre djup och färre nyanser kring hur vårdpersonal resonerar kring de prediktiva modellerna. Eftersom syftet var att förstå läkares och diabetessköterskors syn på maskininläring som ett beslutsstöd bedömdes därmed semi-strukturerade intervjuer som mer lämpligt för att fånga acceptanskriterier.

4.2 Datainsamling

Datakällan för utvecklingen av modellerna är ett utdrag ur det Nationella Diabetesregistret (NDR) från Västra Götalandsregionen. Den ursprungliga filen levererades av NDR-statistiker och i CSV-format samt innehåller 2 167 198 rader. Antalet unika patienter i utdraget är 85 998, den tabellerade informationen i datasetet är följande:

- Ålder
- Diabetesduration
- Diabetestyp
- HbA1c
- BMI
- Systolisk blodtrycksnivå
- Kolesterol
- LDL

Samt de tabellerade utfallsmåttten som ska predikteras vilket inkluderades i datautdraget är följande:

- Diabetisk retinopati
- Diabetisk neuropati

Rader som innehåller saknade värden tas bort eller kompletteras med standardvärden för att minska risken för en försämrad prediktiv förmåga.

Målgruppen för de semi-strukturerade intervjuerna var vårdgivare inom diabetesvården med en klinisk erfarenhet av diabetesvård. Efterfrågan av intervju skickades ut via mejl

och det var frivilligt att delta. Under intervjuerna diskuterades frågor om förtroende av de prediktiva modellerna, acceptans av att inkludera ML vid diagnos av mikrovaskulära komplikationer och vilka sammanhang ML kan fungera bäst. Intervjuerna identifierade även olika acceptanskriterier för prestandan av de prediktiva modellerna. Intervjuerna spelades in och transkriberades därefter för vidare analys.

Data levererades anonymiserat av NDR och hanteras enligt GDPR-riktlinjer av Integritetsskyddsmyndigheten (2025). Data är inte publikt tillgänglig och används samt hanteras enbart inom studiens avgränsning, ingen persondata lämnas ut och enbart resultat av modellerna offentliggörs.

4.3 Bearbetning av data och analys

För bearbetning av CSV-filen från NDR har datasetet importerats in till Jupyter Lab för en övergripande explorativ dataanalys, där syftet var att hitta vanliga problem i datafilen och hantera saknade värden samt brus som filtreras bort inför träningen av modellerna. Baserat på fynden i den explorativa dataanalysen kompletterades eller rensades rader med saknade värden. Efter filtrering exporterades det tvättade datasetet till en CSV-fil och bearbetades vidare i Python för att träna de prediktiva modellerna, där jupyter och scikit-learn utnyttjades.

Datasetet fördelas i två delar med en standarduppdelning där 80 % av datamängden används till träningen av modellerna, och resterande 20 % används för test och utvärdering. Data delades upp stratifierat för att uppnå en jämn andel med och utan komplikation i både träning och testdatasetet. Uppdelningen av datasetet säkerställer modellernas förmåga att generalisera mot ny data. Modellernas hyperparametrar kalibreras innan test för att hitta de inställningar som presterar bäst, dessa används vid testet på testdata. Modellernas prestanda utvärderas med hjälp av resultaten från AUC, F1-score, precision, recall, missfrekvens och FP-frekvens.

En analys utfördes där modellernas prestandaresultat sammanställs och jämförs mot varandra för att visa styrkorna och svagheter hos algoritmerna. Fokus ligger på att jämföra modellernas prestanda och tolka resultaten till en mer praktisk tolkning för att undersöka dess acceptans inom diabetesvården. Resultaten från AUC, F1-score, precision, recall, missfrekvens och FP-frekvens tolkas därmed till antalet falskt positiva respektive falskt negativa fall per 1000 patienter för att ge respondenterna ett konkret exempel på hur modellerna presterar inom en klinisk praxis.

Intervjuerna riktas mot klinisk diabetespersonal och utformas för att mäta tillförlitligheten, implementationshinder och den kliniska acceptansen. Intervjuerna består av strukturerade frågor för acceptans, mottaglighet som beslutsstöd och potentiella hinder inför implementation. Intervjuerna är semi-strukturerade och är öppna för följdfrågor för att få en djupare förståelse av prediktiva modellers plats inom diabetesvården. Intervjuerna kompletterar de kvantitativa resultaten genom att fånga vårdpersonalens bedömning av modellernas praktiska användbarhet. Intervjuerna

jämförs med modellernas prestanda och dess acceptansmått och analyseras med en tematisk analys för att identifiera återkommande teman.

4.4 Forskningsetiska principer

Vetenskapsrådet (2018) beskriver de regler och riktlinjer som forskare bör ta hänsyn till och respektera under en studie. Forskningsetik beskrivs med fyra forskningsetiska principer som bör följas vilket inkluderar: informationskravet, samtyckskravet, konfidentialitetskravet och nyttjandekravet.

Data hämtad från NDR har anonymiserats enligt de riktlinjer som GDPR rekommenderar (Integritetsskyddsmyndigheten, 2025) och ingen personlig information används för att utveckla de prediktiva modellerna. Data som har samlats in kommer även att enbart användas för denna studie för att ta hänsyn till nyttjandekravet som beskrivs av Vetenskapsrådet (2018) och hanteras på ett ansvarsfullt sätt.

Data insamlad från intervjuerna riktas mot vårdpersonal inom diabetesvården och utformas enligt de forskningsetiska principer som beskrivs av Vetenskapsrådet (2018). Respondenter informeras om studiens syfte, vad deras deltagande kommer att innebära, hur deras svar och information lagras samt att deras deltagande är frivilligt vilket tar hänsyn till samtyckeskravet.

För att säkerställa transparens i studien dokumenteras även använda hyperparametrar och prestandamått för modellutvärderingen.

5 Materialpresentation och analys

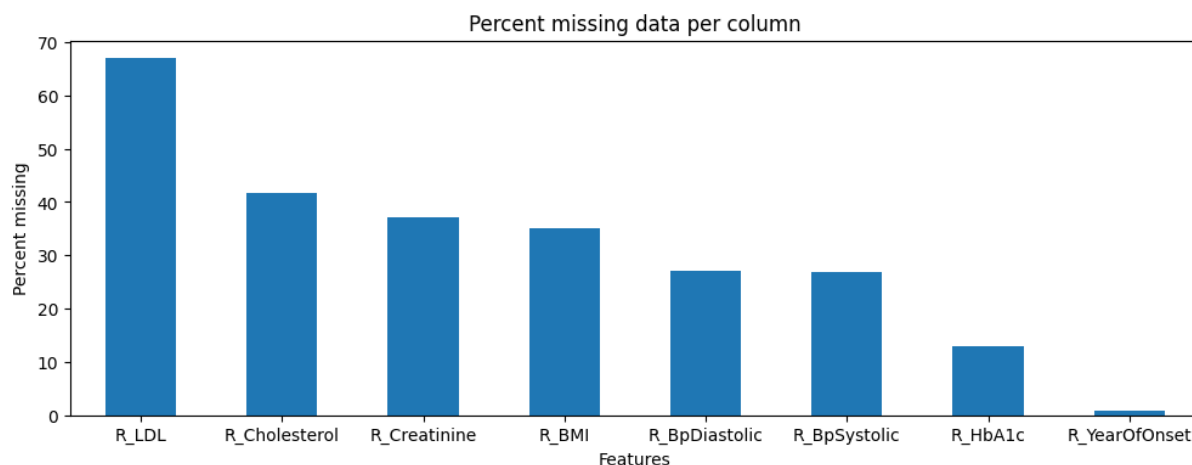
Detta kapitel presenterar och analyserar studiens datamaterial, som består av ett utdrag ur NDR från Västra Götalandsregionen och bearbetningen av materialet inför modellträning. Kapitlet redovisar även modellerna SVM-RBF och Random Forest samt deras prediktiva prestanda och en jämförelse mellan dem. Avslutningsvis analyseras intervjuer med vårdpersonal inom diabetesvården för att undersöka modellernas kliniska acceptans som beslutsstöd.

5.1 Datamaterialets omfattning

Studiens datamaterial bygger på de kliniska registreringar från NDR som infogats i registret i samband med patientens vårdbesök. Registret innehåller information från flera vårdtillfällen och därmed kan en patient förekomma flera gånger i materialet. Den ursprungliga filen levererades i CSV-format och innehåller totalt 2 167 198 rader med 85 998 unika patienter. Därmed beskriver materialet inte enbart enskilda patienter, utan även förändringar i mått över tid.


Datasetet innehåller information om komplikationer samt kliniska mått. De variabler som ingår i utdraget är ålder, kön, diabetestyp, HbA1c, systolisk blodtrycksnivå, kolesterol, BMI, kreatin, kolesterol, LDL och tidpunkt för diagnos. Dessa variabler är inmatningsvariablerna som används för att träna och testa modellerna i studien. Datasetet innehåller även dokumenterad mikrovaskulära komplikationer som ska predikteras vilket är diabetisk retinopati och diabetisk neuropati, dessa är studiens utfallsvariabler. Inmatningsvariablerna och utfallsvariablerna kopplas till en patient för varje besök.

Studiens fokus ligger vid prediktion för typ 1-diabetes och datautdraget från NDR inkluderar endast personer med typ 1-diabetes, de 85 998 unika patienterna är därmed typ 1-diabetespatienter. Den ursprungliga CSV-filen har även enbart patienter som är vuxna, 18 år eller äldre. Datasetet har även saknade värden i flera av inmatnings och utfallsvariablerna.



Figur 5. Inmatningsvariablers procentuella saknade värden.

Figur 5 visar den procentuella andelen av data som saknas för varje inmatningsvariabel i hela datasetet. Variabler som kolesterol, kreatin och LDL har en hög mängd saknade data där uppåt 67 % av data från LDL saknas från grundmaterialet. Variabler som HbA1c och tid för diagnos har en mycket lägre andel data som saknas.



Figur 6. Utfallsvariabler balans och saknade värden.

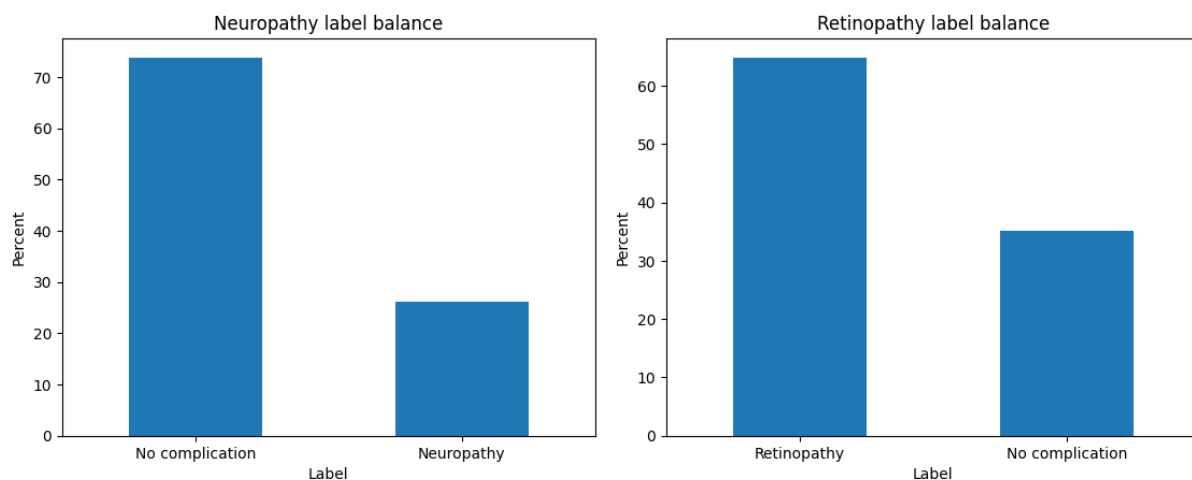
Utfallsvariablerna i datasetet skiljer sig åt och innehåller även saknade värden. Fördelningen av utfallen och saknade värden illustreras i figur 6, där det framgår att en signifikant andel av observationerna saknar värden för både neuropati och retinopati. I den ursprungliga CSV-filen är neuropati kodad så att 1.0 innebär att patienten inte har någon neuropati, medan 2.0, 3.0 och 4.0 motsvarar olika grader av neuropati. Retinopati är kodad på ett annat sätt, där 0.0 innebär att patienten inte har någon komplikation och 1.0 innebär att patienten har retinopati.

Förekomsten av dessa saknade värden och obalanserade etiketter innebär att datasetet behöver bearbetas innan det används för modellträning.

5.2 Bearbetning av utfallsvariabler

För att bearbeta datamaterialet importerades den ursprungliga CSV-filen in till Jupyter Lab för att filtreras och hantera saknade värden. Studien använder två separata utfallsvariabler som inkluderar diabetisk retinopati och diabetisk neuropati. Eftersom komplikationerna är olika och är olika prediktionsproblem hanteras dem separat.

Retinopati är från grunden en binär klassindelning där 0.0 motsvarar att patienten är utan dokumenterad komplikation och klassen 1.0 motsvarar alla patienter med retinopati. Neuropati är inte binär och har därmed omvandlats till en binär klassindelning för att skapa en bättre balans mellan patienter med och utan neuropati. Neuropati ändrades därmed till att patienter tilldelas en 0.0 för patienter utan dokumenterad komplikation och 1.0 för patienter som ursprungligen hade klassen 2.0, 3.0 eller 4.0. Alla rader med patienter som saknade en etikett raderades inför träningen av modellerna, eftersom det inte går att identifiera om patienten har en komplikation, för att undvika felaktig prediktion.



Figur 7. Utfallsvariabler balans efter bearbetning.

Figur 7 visar fördelningen mellan de två utfallsvariablerna efter bearbetning av datamaterialet. Det framgår att klasserna inte är jämnt fördelade, vilket innebär att vissa utfall förekommer oftare än andra i materialet. Observationerna utan en etikett har tagits bort för att endast använda patienter med kända utfallsvariabler.

Klassobalansen kan även påverka modellernas förmåga att identifiera den mindre representerade klassen. Klasserna ligger till grund för studiens modeller.

5.3 Bearbetning av inmatningsvariabler

För att hantera saknade värden hos inmatningsvariablerna var det inte lämpligt att ta bort rader som saknade vissa av de kliniska måtten. Majoriteten av raderna i den ursprungliga CSV-filen saknade minst ett kliniskt mått och en stor del av materialet skulle då gå förlorat. I stället användes en imputering på dessa numeriska kliniska mått som saknades och ersattes med den variabelns medianvärde, där median valdes eftersom den är mindre känslig mot extrema värden än medelvärde. Efter imputeringen standardiseras alla inmatningsvariabler så att variablerna har en jämförbar skala inför test och träning av modellerna.

Under utvecklingen av modellerna testades flera variabler och vissa variabler exkluderades på grund av deras betydelse för prediktionen. De kliniska måtten som exkluderades var BMI, blodtryck och LDL som hade en låg vikt vid prediktion av både retinopati och neuropati. Exempelvis visade LDL lägst betydelse vid prediktion med en vikt av enbart 5 %, en anledning till detta kan bero på att för variabeln LDL fattades det över 67 % av all data.

Inmatningsvariablerna som användes i modellerna valdes utifrån deras kliniska koppling till mikrovaskulära komplikationer och test av betydelse för prediktion.

Tid för diagnos användes som ett mått på hur länge en patient har haft diabetes, enligt Lu et al. (2023) finns det en stark korrelation mellan hur länge en patient har haft diabetes

och utveckling av mikrovaskulära komplikationer. Detta gör variabeln relevant för prediktion för både retinopati och neuropati.

HbA1c beskriver en patients långsiktiga blocksockernivå och används för att mäta hur patientens diabetes har reglerats. För att undvika mikrovaskulära komplikationer behöver patienten hålla en stabil nivå av HbA1c (Lu et al., 2023). Variabeln är relevant för att beskriva hur stabil HbA1c har varit under en längre tid.

Kreatin och **kolesterol** är beskrivande kliniska mått som har indirekta samband med mikrovaskulära komplikationer. Kreatin och kolesterol har tidigare haft en signifikant betydelse vid prediktion för mikrovaskulära komplikationer och är relevanta för att utveckla modellerna (Du et al., 2025).

5.4 Modell 1: SVM-RBF

Studien använder sig av Support Vector Machine med RBF-kärna (SVM-RBF) som en av de två prediktionsmodellerna. Modellen importerades med hjälp av scikit-learn och användes för att prediktera förekomsten av diabetisk retinopati och diabetisk neuropati utifrån det filtrerade datasetet med de utvalda inmatningsvariablerna. SVM-RBF har fördelen att den kan hantera klassificeringar med data som inte är linjära och identifiera mer komplexa mönster (Géron, 2019).

För att konfigurera modellernas hyperparametrar och hyperparameteroptimering rekommenderar Géron (2019) att använda scikit-learns GridSearch funktion med korsvalidering. Funktionen itererar genom de olika hyperparametrarna för att hitta den optimala konfigurationen för den data som den har tillgång till för att uppnå en högre precision.

Studien innehåller två olika prediktionsproblem, diabetisk retinopati och diabetisk neuropati, och därmed utförs två olika prediktioner separat. SVM-RBF modellen har genomgått två olika hyperparameteroptimeringar och resultatet av korsvalideringen för båda prediktionsproblemen visas i tabell 1:

Tabell 1. Hyperparametrar för olika prediktionsproblem SVM-RBF.

Prediktionsproblem	Hyperparameter: C	Hyperparameter: Gamma
Diabetisk retinopati	10	0,01
Diabetisk neuropati	1	scale

Tabell 1 visar de hyperparametrar som gav bäst resultat vid korsvalideringen och den visar att det finns en skillnad mellan retinopati och neuropati. Skillnaden visar att det fanns olika datamönster och därmed krävde olika inställningar för att uppnå bättre prestanda. Dessa är de slutgiltiga hyperparametrarna som användes för att träna och utvärdera modellen.

5.4.1 Prediktiv prestanda för retinopati

Modellen har tränats på 80 % av datasetet som innehåller diabetisk retinopati och därefter utvärderades på resterande 20 % av datasetet. Modellen utvärderas med ett AUC-värde, F1-score, precision och recall i tabell 2:

Tabell 2. Resultat av prediktiv förmåga hos SVM-RBF för diabetisk retinopati.

Utvärderingsmått:	Precision	Recall	F1-score	AUC
Resultat:	0,84	0,74	0,79	0,81

Tabell 2 visar resultatet för prediktionen av diabetisk retinopati och SVM-RBF-modellen gav en precision på 0,84, recall på 0,74, ett F1-score på 0,79 och ett AUC-värde på 0,81. Modellen visar en hög precision vilket innebär att när modellen förutspådde retinopati var den ofta korrekt med prediktionen. Recall visar att modellen missade en del verkliga fall efter. F1-score visar det harmoniska medelvärdet mellan precisionen och recall. För att se det praktiskt sett visas resultatet i en förväxlingsmatrix i tabell 3:

Tabell 3. Förväxlingsmatrix över SVM-RBF för diabetisk retinopati.

Förväxlingsmatrix SVM-RBF över retinopati	Predikterad positiv	Predikterad negativ
Faktisk positiv	155 916 (TP)	52 329 (FN)
Faktisk negativ	29 404 (FP)	83 523 (TN)

Förväxlingsmatrisen för retinopati hos SVM-RBF-modellen visar att modellen klassificerade 155 916 fall korrekt som positiva retinopati fall, samt 83 523 fall som korrekt negativa. Modellen visade även att den missade 52 329 positiva fall och klassificerade dem som utan komplikation, samt klassificerade 29 404 fall felaktigt som positiva. Detta innebär att när modellen förutsäger att en patient har diabetisk retinopati, missas 25 % av dessa fall. För varje 1000 patienter kommer modellen att missa 250 patienter som har retinopati. Frekvensen för falska positiva fall (FP) ligger på 26 % och innebär att modellen felaktigt förutsäger att 260 patienter av 1000 har retinopati.

Detta visar på att modellen har något mer träffsäkerhet vid prediktion för ett positivt fall jämfört med prediktion av den negativa klassen. Med studiens syfte i åtanke visar det att modellen har en tydlig prediktiv förmåga för att identifiera patienter med retinopati, men att den inte lyckas fånga alla patienter.

5.4.2 Prediktiv prestanda för neuropati

För att utvärdera modellens prediktiva förmåga för att identifiera patienter med neuropati användes det bearbetade dataset som innehåller etiketten diabetisk neuropati. Modellen följer samma process där modellen tränades på 80 % av datasetet och

utvärderas därefter på resterande 20 % av datasetet. Modellen utvärderas med ett AUC-värde, F1-score, precision och recall i tabell 4:

Tabell 4. Resultat av prediktiv förmåga hos SVM-RBF för diabetisk neuropati.

Utvärderingsmått:	Precision	Recall	F1-score	AUC
Resultat:	0,47	0,66	0,55	0,76

Tabell 4 visar resultatet för prediktionen av diabetisk neuropati och SVM-RBF modellen gav en precision på 0,47, recall på 0,66, ett F1-score på 0,55 och ett AUC-värde på 0,76. Jämfört med retinopati har modellen svårt för att identifiera patienter med neuropati, precisionen är det lägsta värdet vilket visar att modellen presterade dåligt när den skulle prediktera ett positivt utfall av neuropati. För ett förtydligande visas resultaten i en förväxlingsmatris i tabell 5:

Tabell 5. Förväxlingsmatris över SVM-RBF för diabetisk neuropati.

Förväxlingsmatris SVM-RBF över neuropati	Predikterad positiv	Predikterad negativ
Faktisk positiv	43 579 (TP)	21 954 (FN)
Faktisk negativ	48 404 (FP)	136 239 (TN)

Förväxlingsmatrisen för neuropati visar att SVM-RBF-modellen klassificerade 43 579 fall som korrekt positiva samt 136 239 som korrekt negativa. Modellen identifierade däremot 21 954 positiva fall som felaktigt negativa, samt identifierade den 48 404 negativa fall som felaktigt positiva. Missfrekvensen för modellen är 34 % för patienter som faktiskt har neuropati, detta innebär att för varje 1000 patienter som modellen predikterar missas 340 faktiska fall av neuropati. Frekvensen för falska positiva fall (FP) är betydligt lägre där 26 % av alla fall fel klassificeras som positiva och 260 av 1000 patienter fel klassificeras.

Modellens höga missfrekvens kan bero på att datasetet är obalanserat då den negativa klassen utgör 74 % av hela datasetet och har därmed en bias mot negativa utfall. Modellen har svårt att identifiera patienter med neuropati men fångar de flesta negativa fallen.

5.5 Modell 2: Random Forest

Studiens andra prediktiva modell är Random Forest modellen som är en ensemblemetod som använder sig av flera beslutsträd (Badawy et al., 2023; Fife & D'Onofrio, 2023). För att komma fram till sitt resultat kombinerar modellen alla resultat från de olika beslutsträden för att få fram det slutgiltiga resultatet (Badawy et al., 2023). Fördelen med en Random Forest modell är att den generaliserar sig bra mot ny data och hanterar större

dataset enklare, men den kan vara känslig mot modellens hyperparametrar (Badawy et al., 2023).

För att bestämma modellens hyperparametrar användes samma process GridSearch-korsvaliderings process som Géron (2019) rekommenderar. Modellen gick igenom två omgångar av hyperparameteroptimering för att bestämma vilka hyperparametrar som är mest optimala för varje prediktionsproblem. De hyperparametrar som användes visas i tabell 6:

Tabell 6. Hyperparametrar för olika prediktionsproblem Random Forest.

Prediktionsproblem	Hyperparameter: n_estimators	Hyperparameter: max_depth
Diabetisk retinopati	200	20
Diabetisk neuropati	200	20

Korsvalideringen gav samma resultat för hyperparametrar för både neuropati och retinopati. Utvärderingen och träningen av modellen använder sig av de hyperparametrar som visas i tabell 6.

5.5.1 Prediktiv prestanda för retinopati

Random Forest-modellen har tränats på retinopati datasetet och följer samma process som SVM-RBF-modellen där 80 % av datasetet användes till träningen och utvärderades på resterande 20 %. Modellens resultat visas i tabell 7:

Tabell 7. Resultat av prediktiv förmåga hos Random Forest för diabetisk retinopati.

Utvärderingsmått:	Precision	Recall	F1-score	AUC
Resultat:	0,81	0,82	0,81	0,82

För prediktionen av diabetisk retinopati gav Random Forest-modellen en precision på 0,81, recall på 0,82, ett F1-score på 0,81 och ett AUC-värde på 0,82. Resultatet tyder på att modellen hade en bra balans för att prediktera patienter med och utan retinopati. Resultaten visar att det finns en god prediktiv förmåga men att den inte fångar alla patienter. För ett praktiskt exempel visas resultatet i en förväxlingsmatris i tabell 8:

Tabell 8. Förväxlingsmatris över Random Forest för diabetisk retinopati.

Förväxlingsmatris Random Forest	Predikterad positiv	Predikterad negativ
Faktisk positiv	170 763 (TP)	37 482 (FN)
Faktisk negativ	39 017 (FP)	73 910 (TN)

Förväxlingsmatrisen visar att modellen korrekt identifierade 170 763 fall som korrekt positiva fall, samt identifierade den 73 910 fall som korrekt negativa fall. Tabell 8 visar även hur modellen missade 37 482 positiva fall och identifierade dem som negativa samt klassificerade modellen 39 017 negativa fall som positiva. Missfrekvensen för Random Forest för retinopati är 18 % vilket innebär att 180 av 1000 patienter med retinopati identifieras som negativa fall. Modellen har däremot en betydligt högre frekvens för falska positiva fall (FP) där modellen identifierade 35 % av alla negativa fall som falskt positiva.

Modellen väljer över lag att identifiera fler patienter som positiva och förväxlar fler negativa fall som positiva. Detta kan bero på att det finns en obalans mellan den positiva klassen som är 65 % av det totala datasetet och den negativa klassen.

5.5.2 Prediktiv prestanda för neuropati

Liknande vid utvärderingen av den prediktiva förmågan för Random Forest för retinopati har modellen tränats på neuropati datasetet med samma process. Resultatet visas i tabell 9 nedan:

Tabell 9. Resultat av prediktiv förmåga hos Random Forest för diabetisk neuropati.

Utvärderingsmått:	Precision	Recall	F1-score	AUC
Resultat:	0,59	0,48	0,53	0,79

För prediktion av diabetisk neuropati visade modellen ett resultat som gav en precision på 0,59, recall på 0,48, ett F1-score på 0,53 och ett AUC-värde på 0,79. AUC-värdet tyder på att modellen kan separera mellan klasserna någorlunda men presterar sämre vid precisionen och recall vilket leder till ett svagare F1-score. Liknande vid prediktion av neuropati för SVM-RBF-modellen visar Random Forest-modellen en över lag sämre prestanda jämfört med retinopati. För en mer detaljerad bild visas även en förväxlingsmatris för modellen i tabell 10:

Tabell 10. Förväxlingsmatris över Random Forest för diabetisk neuropati.

Förväxlingsmatris Random Forest	Predikterad positiv	Predikterad negativ
Faktisk positiv	31 418 (TP)	34 115 (FN)
Faktisk negativ	21 902 (FP)	162 741 (TN)

Eftersom datasetet är obalanserat finns det en större mängd negativa fall än positiva fall. Förväxlingsmatrisen visar att modellen korrekt identifierade 31 418 fall som positiva samt 162 741 fall som negativa. Samtidigt klassificerade modellen 34 115 positiva fall som negativa och 21 902 negativa fall som positiva. Detta innebär att missfrekvensen för modellen var 52 %, vilket betyder att 520 av 1000 patienter med neuropati klassificeras som utan. Frekvensen för falska positiva fall (FP) är däremot betydligt mindre där endast 12 % av negativa fall identifieras som positiva. Enbart 120 av 1000 patienter identifieras fel vid prediktion av negativa fall.

Modellen visar att den är mycket träffsäker för att identifiera patienter utan neuropati. Den drastiska missfrekvensen och nedsatta prestandan kan bero på obalansen i datasetet. Dagliati et al. (2018) visar i sin studie att en modell med ett obalanserat dataset har en sämre prestanda jämfört med modeller som tränats på data med balanserade klasser. Detta betyder att modellen har tränats opropotionellt mot en klass och har en bias.

5.6 Jämförelse mellan SVM-RBF och Random Forest

För att jämföra modellernas prediktiva förmåga för både retinopati och neuropati presenteras deras individuella prestanda för varje prestandamått i tabell 11:

Tabell 11. Sammanfattande tabell för prestanda av SVM-RBF och Random Forest.

Modell	Precision (Retinopati)	Recall (Retinopati)	F1-score (Retinopati)	AUC (Retinopati)	Missfrekvens (Retinopati)	FP-frekvens (Retinopati)
SVM-RBF	0,84	0,74	0,79	0,81	25 %	26 %
Random Forest	0,81	0,82	0,81	0,82	18 %	35 %
Modell	Precision (Neuropati)	Recall (Neuropati)	F1-score (Neuropati)	AUC (Neuropati)	Missfrekvens (Neuropati)	FP-frekvens (Neuropati)
SVM-RBF	0,47	0,66	0,55	0,76	34 %	26 %
Random Forest	0,59	0,48	0,53	0,79	52 %	12 %

Vid jämförelsen av modellernas prestanda gällande prediktion för diabetisk retinopati och diabetisk neuropati framträder det ett tydligt mönster där båda modellerna presterar bättre för retinopati. För retinopati ligger båda modellerna på en relativt hög nivå för precision, recall, F1-score, AUC, missfrekvens och FP-frekvens. För neuropati visar modellerna en lägre nivå för samtliga mått. Det tyder på att retinopati är enklare att prediktera jämfört med neuropati utifrån datamaterialet. Det stämmer även överens med att balansen mellan klasserna i neuropati datasetet var svagare, där den negativa klassen dominerade datasetet. Detta ligger i linje med tidigare forskning som visar att prestandan påverkas av obalansen mellan klasser. Dagliati et al. (2018) beskriver till exempel att modeller som tränades på obalanserad data presterade sämre än modeller med balanserade klasser, vilket även syns i denna studie.

För retinopati hade Random Forest-modellen en högre recall, F1-score samt AUC jämfört med SVM-RBF. Modellen missar även färre fall av retinopati än SVM-RBF-modellen men är sämre på att identifiera negativa fall och har en bias mot positiva fall. SVM-RBF har däremot en högre precision och missar flera positiva fall men är mer balanserad mellan missfrekvensen och FP-frekvensen.

För neuropati är skillnaden mellan modellerna tydligare. SVM-RBF har en högre recall samt en lägre missfrekvens än Random Forest, vilket innebär att den hittar fler patienter som faktiskt har neuropati. Random Forest har däremot en högre precision men en lägre recall och konsekvent en högre missfrekvens, och missar därmed flera verkliga fall. Random Forest visar även en signifikant obalans mellan missfrekvens och FP-frekvens, med en 52 % missfrekvens och en betydligt lägre 12 % FP-frekvens. Det tyder på att modellerna förhåller sig olika vid prediktion och det framgår att Random Forest-modellen påverkas mer av klassobalansen jämfört med SVM-RBF-modellen.

5.7 Intervjuanalys

De semi-strukturerade intervjuerna genomfördes med en läkare (respondent 1) och två diabetessköterskor (respondent 2 och respondent 3). Intervjusvaren har transkriberats för att effektivt analysera svaren och identifiera teman för att jämföra med tidigare forskning. Intervjuerna syftar till att identifiera den praktiska acceptansen av maskininlärning och domänexperters åsikter för maskininlärning som beslutsstöd och identifiera acceptanskriterier. Målet är att skapa en fördjupande förståelse av olika hinder samt möjligheter maskininlärning har vid identifiering av mikrovaskulära komplikationer.

Intervjuerna resulterade i flera teman som analyserades och jämförs med tidigare forskning. De teman som framstod från datainsamlingen var följande:

- Klinisk bedömning och arbetsflöde
- Krav för klinisk tillit till maskininlärning
- Balans mellan missade och falska fall
- Praktisk tillämpning av maskininlärning inom vården

Intervjuerna genomfördes efter utvecklingen av modellerna och användes som grund för att undersöka hur modellernas prestanda kan förstås i relation till det kliniska arbetet, tilliten och den praktiska användningen av modellerna.

5.7.1 Klinisk bedömning och arbetsflöde

I samtliga intervjuer framkom det att bedömningen av mikrovaskulära komplikationer i dag bygger på olika kliniska underlag. Respondent 1 beskriver att blodprov, patientens medicinska historik, hur länge patienten har haft diabetes samt manuella undersökningar används för att komma fram till en diagnos. Det ligger i linje med Lu et al. (2023) som beskriver olika manuella undersökningar för att identifiera retinopati och neuropati. Respondent 1 betonar: *”Vid medicinsk diagnostik är det den medicinska historiken som har störst betydelse”*. Respondent 2 och respondent 3 beskriver en liknande process vid bedömning där respondenten även nämner att nivå av HbA1c, blodtryck samt laboratorieresultat används som underlag. Detta visar att klinisk bedömning i dag utgår från en kombination av patientens uppgifter, laboratorieresultat och manuella undersökningar.

Detta stämmer överens med tidigare forskning som lyfter fram att kliniska variabler som HbA1c och diabetesduration ligger till grund för prediktion av mikrovaskulära komplikationer. Kanbour et al. (2024) beskriver exempelvis att patientjournaler som innehåller patientens medicinska historik används som grund för prediktion av mikrovaskulära komplikationer. Du et al. (2025) lyfter även fram flera kliniska variabler som används för prediktion av komplikationer, som även återkommer i denna studie som centrala inmatningsvariabler.

5.7.2 Krav för klinisk tillit till maskininlärning

Ett tydligt tema i intervjuerna är att det måste vara möjligt att se hur modellen har kommit fram till beslutet för att den ska uppfattas som pålitlig. Vid frågeställning om vad som väger tyngre, en träffsäker modell eller en modell som är enklare att förstå, betonar respondent 1: *”Ju enklare, desto bättre. Jag vill se hur den kom fram till sitt beslut och varför”*. Respondent 2 resonerar liknande: *”Jag vill förstå och kunna förklara för patienten hur modellen har kommit fram till sitt beslut”*. Respondent 2 och respondent 3 nämner att en mer förståelig modell är särskilt värdefull i den praktiska vården, då det är viktigt för att förstå resultatet och även förklara beslutet för patienten. Det är i linje med Dagliati et al. (2018) som beskriver att en enklare men mer förståelig modell är att föredra i en klinisk kontext. Detta innebär att tillit inte bara handlar om hur modellen presterar, utan också förklarbarheten och möjligheten att följa modellens beslutsfattnings process.

Dagliati et al. (2018) framhåller även att valet av modell för en uppgift blir en avvägning mellan modellens prestanda och tolkningsbarheten av modellen, vilket återspeglas i intervjuerna. I detta sammanhang blir det tydligt att en modell med en hög numerisk prestanda inte nödvändigtvis är den modell som presterar bäst praktiskt inom vården.

Respondent 1 och respondent 2 nämner även att tilliten till maskininlärning och modellerna kopplas till ansvar. Båda respondenterna understryker att vid diagnos är det läkaren som bär ansvaret vid potentiella fel. Respondent 1 menar att även om förståelsen för hur modellen kom fram till beslutet är viktig, är träffsäkerheten även central då läkaren är den som bär ansvaret vid feldiagnos.

När respondenterna resonerade kring en acceptabel felmarginal för att använda maskininlärning som ett beslutsstöd framkom det även att modellen behöver prestera högt. Du et al. (2025) utvecklade i deras studie en XGBoost-modell för att prediktera nefropati hos diabetiker, som visade en hög prestanda på 0,83 AUC, samt beskriver de att resultatet visar en potential för klinisk adoption. Random Forest-modellen i den här studien uppnådde ett AUC på 0,82 samt 18 % missfrekvens och 35 % FP-frekvens vid prediktion av retinopati. Däremot visar intervjuerna med beslutsfattare inom diabetesvården att de inte skulle vara bekväma med att använda en modell med en sådan hög felmarginal. Som krav för modellernas felmarginal beskriver respondent 1: *"Något jag skulle vara bekväm med är 5–7 % felmarginal. Generellt sett tror jag att allt inom den medicinska världen kräver en hög grad av precision"*. Respondent 2 och respondent 3 gav ett liknande svar där en träffsäkerhet på 95 % och 90 % angavs som krav för att lita på modellens beslut.

5.7.3 Praktisk betydelse av missade och falska fall

Ett ytterligare tema från intervjuerna är betydelsen av olika typer av fel. Samtliga respondenter bedömer att falskt negativa fall är särskilt problematiska, där de resonerar att det innebär att en komplikation kan missas. Samtliga respondenter uttrycker att ett falskt negativt resultat är mer allvarligt än ett falskt positivt resultat ur en patientsäkerhetssynpunkt, eftersom det kan leda till att vården inte upptäcker komplikationen i tid. Respondent 3 uttrycker att ett falskt positivt resultat inte ger några konsekvenser för patienter. Respondent 2 uttrycker däremot att falskt positiva resultat också är ett problem eftersom det kan skapa extra oro hos patienten. Respondent 1 lägger däremot högre vikt vid falskt positiva resultat. Respondent 1 betonar: *"Om du får samma falskt positiva resultat flera gånger, så kan du börja behandla det som sådant, även om det inte är det"*, vilket kan påverka patientens hälsa negativt.

Badawy et al. (2023) lyfter även hur felaktiga prediktioner kan påverka patienthälsan negativt, men nämner inte vilket typ av fel som påverkar patienten mer. Detta är särskilt relevant i relation till modellresultaten, eftersom modellerna visar en olika balans mellan typerna av fel vid prediktion. En högre missfrekvens innebär att modellen missar patienter med komplikation, medan ett högre antal falskt positiva fall innebär att patienter riskerar att få en feldiagnos och behandlas i onödan.

Under intervjuerna framkom det därför att det inte är tillräckligt med en hög träffsäkerhet. Det är även viktigt att överväga vilken typ av fel modellen gör, hur balanserade de är och hur feLEN påverkar det kliniska arbetet. För respondenterna finns

det en balans mellan hur båda typerna av fel kan påverka patienten negativt, men att falskt negativa resultat kan ses som mer oroväckande.

5.7.4 Praktisk tillämpning av maskininlärning inom vården

Ett annat tydligt tema som framkom under intervjuerna är hur en prediktiv modell som beslutsstöd bör tillämpas i praktiken. Den kliniska relevansen av maskininlärning bygger på hur beslutsstödet kan tillämpas och vad den tillför i praktiken. Respondent 1 beskriver hur beslutsstödet resultat kan ha en stor inverkan för att hjälpa läkare vid diagnostisering samt väcka misstanke för komplikation, däremot uttrycker han även att det inte bör användas som ett självständigt diagnostiskt verktyg. Vid resonemang kring risker med att använda ett sådant beslutsstöd uttrycker respondent 1: *"Om du ger någon något för att göra deras jobb enklare, kan de förlita sig för mycket på det, och förlora deras expertis och bli självbelåtna"* och *"Men över lag tror jag att om det implementeras på rätt sätt, skulle det bli väldigt bra"*. Det ligger i linje med Badawy et al. (2023) och Habehh & Gohel (2021), som beskriver att prediktiva modeller inom vården måste användas med klinisk tillsyn eftersom ett felaktigt beslut kan få allvarliga konsekvenser. Respondent 2 och 3 resonerar liknande där de beskriver att läkare bör vara den som sätter diagnos men att beslutsstödet kan vara relevant vid screening för komplikation.

En prediktiv modell som beslutsstöd uppfattas främst som ett komplement till den kliniska bedömningen snarare än som ett verktyg för diagnostik. För att modellen ska vara kliniskt relevant som beslutsstöd behöver den därför integreras på ett sätt som skapar tillit till modellen. Detta är relevant till denna studie för hur modellerna bör utvärderas för att visa om modellerna uppnår en prestanda som bedöms som kliniskt relevant och acceptabel.

5.8 Klinisk acceptans av SVM-RBF och Random Forest

Intervjuerna med beslutsfattare inom diabetesvården visar att den kliniska acceptansen för en prediktiv modell inte enbart avgörs av en hög numerisk prestanda, utan även hur modellen förhåller sig till patientsäkerhet, modellens förklarbarhet och dess praktiska användning. För en sammanfattning av intervjuerna gav för acceptanskriterier visas det i tabell 12:

Tabell 12. Kliniska acceptanskriterier för prediktiv modell som beslutsstöd.

Kliniska acceptanskriterier	Resultat från intervju	Tolkning för modell
Felmarginal	Felmarginal mellan 5–10 % räknas som acceptabel.	En modell behöver prestera högt numeriskt.
Missfrekvens vs FP-frekvens	Missfrekvens uppfattas som mest problematiska, FP-frekvens skapar en oro och fel bedömningar.	Modeller med lägre missfrekvens bedöms som bättre.
Praktisk tillämpning	Modellen ska stöda läkare och diabetessköterska inte ersättas.	Användning som beslutsstöd är mer acceptabelt än för diagnostik.
Förklarbarhet	Modell måste kunna visa hur och varför den kommer fram till sitt resultat.	En klinisk accepterad modell kräver mer än enbart en hög prestanda.

Som nämnts tidigare framgår det i tabell 12 att den kliniska acceptansen för en prediktiv modell inte enbart beror på modellens numeriska prestanda. Därmed används acceptanskriterierna felmarginal och balansen mellan missfrekvens och FP-frekvens för att utvärdera modellernas acceptansnivå. Detta överensstämmer med Badawy et al. (2023), som framhåller att felaktiga prediktioner, falskt positiva och negativa prediktioner, inom hälso- och sjukvården kan få allvarliga konsekvenser. Det innebär att modellerna utvärderas utifrån deras kliniska acceptans, då det är viktigt för att visa modellens praktiska värde som beslutsstöd.

När modellernas prestanda jämförs utifrån dessa kriterier framträder olika styrkor. För diabetisk retinopati har Random Forest lägre missfrekvens än SVM-RBF (se tabell 11), vilket innebär att modellen missar färre verkliga fall. Samtidigt har Random Forest en högre FP-frekvens än SVM-RBF. Detta innebär att Random Forest-modellen fångar fler patienter med retinopati, men att den också ger fler felaktiga positiva prediktioner. Eftersom patientsäkerhet och risken att missa verkliga fall prioriteras högst framstår Random Forest-modellen som att vara närmare en kliniskt acceptabel nivå jämfört med SVM-RBF.

För prediktion av diabetisk neuropati framträder en annan bild. Här har SVM-RBF-modellen en mer balanserad relation mellan missfrekvens och FP-frekvens samt en lägre

missfrekvens än Random Forest (se tabell 11). Random Forest visar en betydligt högre missfrekvens på 52 %, vilket innebär att modellen missar majoriteten av de verkliga fallen. Random Forest-modellen visar även en bias mot negativa fall vid prediktion, som kan få konsekvenser vid klinisk tillämpning. Risker att missa verkliga fall prioriteras högre och därmed framstår det som att SVM-RBF-modellen är närmare de kliniskt acceptabla måtten vid prediktion av diabetisk neuropati.

Sammanfattningsvis visar analysen att klinisk acceptans inte kan bedömas enbart utifrån ett högt AUC-värde eller F1-score. För retinopati är Random Forest den modell som bäst motsvarar de acceptanskriterier som framkom i intervjuerna, eftersom modellen missar färre verkliga fall. För neuropati ligger däremot SVM-RBF närmare kriterierna, eftersom modellen både har en lägre missfrekvens och är mer balanserad, vilket tyder på en mindre bias mot en specifik prediktion.

6 Resultat

För att besvara studiens forskningsfråga: "Vilken prediktiv modell presterar bäst för att identifiera typ 1-diabetespatienter med risk att utveckla diabetisk retinopati och neuropati?" har två prediktiva modeller, SVM-RBF och Random Forest, jämförts genom prestandamått och acceptanskriterier identifierade från intervjuer med beslutsfattare.

6.1 Modellernas prediktiva prestanda

Modellerna tränades på data från ett diabetesregister från NDR och utvärderades med avseende på sin förmåga att identifiera patienter med retinopati och neuropati. Tabell 13 sammanfattar modellernas prestanda:

Tabell 13. Sammanfattande resultat av prestanda vid prediktion.

Modell	AUC	Missfrekvens	FP-frekvens	Felmarginal	Prediktionsproblem
SVM-RBF	0,81	25 %	26 %	>10 %	Retinopati
Random Forest	0,82	18 %	35 %	>10 %	Retinopati
SVM-RBF	0,76	34 %	26 %	>10 %	Neuropati
Random Forest	0,79	52 %	12 %	>10 %	Neuropati

För prediktion av retinopati uppnådde Random Forest ett AUC-värde på 0,82, medan SVM-RBF uppnådde ett AUC-värde på 0,81. Random Forest hade en missfrekvens på 18 % och en FP-frekvens på 35 %. SVM-RBF hade en missfrekvens på 25 % och en FP-frekvens på 26 %. Random Forest har en bias till den positiva klassen för retinopati, men modellen missade färre verkliga fall. Samtliga modeller visar även en felmarginal som överstiger den identifierade maximala acceptabla felmarginalen vid 10 %.

Neuropatidatan har en högre obalans än retinopatidatan, där den negativa klassen är dominerande. För prediktion av neuropati uppnådde SVM-RBF-modellen en högre prestanda än Random Forest. SVM-RBF har en betydligt bättre förmåga att hantera obalanserade klasser jämfört med Random Forest. Vid neuropatiprediktion har Random Forest en tydlig bias, där modellen missklassificerade 52 % av faktiska fall; modellen är därmed inte pålitlig. AUC-värdet för neuropati visar att Random Forest har en högre grad av prestanda men visar inte hur modellen predikterar, därför används balansen vid prediktion för att värdera modellens prediktiva förmåga. Det stöds även av Dagliati et al. (2018), som visar att obalanserade dataset kan påverka modellernas prestanda och att en högre AUC inte nödvändigtvis ger en fullständig bild av modellernas kliniska användbarhet.

Modellernas inmatningsvariabler ligger i linje med tidigare forskning där både Du et al. (2025) och Kanbour et al. (2024) rapporterade mätvärden som HbA1c, diabetesduration, kreatinin och kolesterol, vilket överensstämmer med de inmatningsvariabler som användes i denna studie.

6.2 Acceptanskriterier för prediktiva modeller

Intervjuerna med vårdpersonal inom diabetesvården visar att modellerna i första hand uppfattas som beslutsstöd. Respondenterna beskrev att maskininlärning kan vara användbart för att väcka misstanke om komplikationer och stödja läkare vid diagnostisering, men att det inte bör användas som ett självständigt diagnostiskt verktyg. Intervjuerna resulterade även i olika acceptanskriterier för prediktiva modeller för klinisk tillämpning.

De resulterande acceptanskriterierna är följande:

- Modellen ska uppnå en låg (5–10 %) felmarginal vid prediktion av mikrovaskulära komplikationer.
- För att skapa tillit till modellen bedöms missfrekvens som tyngre och bör prioriteras vid prediktion.
- Att modellen inte agerar som ett diagnostiskt verktyg utan i stället exklusivt som beslutsstöd.
- Modellen visar en motivering till hur den kom fram till beslutet för att skapa en förståelse.

En viktig del av prediktiv analys är hur tillförlitligt resultatet är och hur det används. Om en modell inte är kliniskt accepterad uppfyller modellen inte något syfte. Acceptanskriterierna ligger till grund för att utvärdera modellernas kliniska acceptansnivå.

En central del av analysen var hur modellerna hanterar olika typer av fel, missfrekvens och FP-frekvens. Resultaten visar att det finns en tydlig avvägning mellan de olika typerna av fel i linje med Dagliati et al. (2018). Balansen mellan dessa typer av fel är särskilt viktig i en klinisk kontext där konsekvenserna av att missa ett fall ofta är mer allvarliga. Det framkom även att det är viktigt med en generellt låg procentuell felmarginal för att uppfattas som kliniskt acceptabel för användning.

Respondenterna beskrev ett krav på att modellen bör användas som beslutsstöd och inte som ett självständigt diagnostiskt verktyg, där det slutliga diagnostiska ansvaret ligger hos användaren. Modellernas prestandamått utvärderas inte med detta acceptanskrav då ansvaret ligger hos användaren.

Ett annat tydligt krav är förståelse av modellernas prediktioner och motivering. Där beslutsfattare anger att modellen ska visa en motivering till beslutet som ett krav, för att skapa tillit till modellen och även möjliggöra motivering vid diagnos.

6.3 Sammanfattande slutsats av modellernas kliniska acceptans

Sammantaget visar resultaten att Random Forest presterar bäst för diabetisk retinopati, där modellen missar färre verkliga fall och uppnår en högre prestanda vid analys av prestandamått. SVM-RBF presterar bäst för diabetisk neuropati där modellen har en lägre missfrekvens samt förhåller sig bättre till de obalanserade klasserna. Däremot uppnår ingen av modellerna de acceptanskriterier som ställs av beslutsfattare inom diabetesvården. Resultatet för studien visas i tabell 14:

Tabell 14. Resultat av bäst presterande modell och dess acceptansnivå.

Prediktionsproblem	Högst presterande modell	Styrka	Svaghet	Acceptansnivå
Diabetisk retinopati	Random Forest	Missar färre verkliga fall med en missfrekvens på 18 %.	Visar stark bias mot den dominerande klassen, med 52 % missfrekvens vid hög obalans.	Inte acceptabel. Kräver en lägre felmarginal och förklarbarhet av beslut.
Diabetisk neuropati	SVM-RBF	Hanterar obalanserade klasser bättre, med en tydligare jämn fördelning.	Genererar en högre andel falsk positiva prediktioner. Klassbalanseringen ökar generellt FP-frekvensen.	Inte acceptabel. Kräver en lägre felmarginal och förklarbarhet av beslut.

Utvärderingen av modellerna baserades på deras prestandamått samt dess kliniska acceptansnivå, där modellen som uppnår en lägre felmarginal och missfrekvens värderas högre.

Styrkan med Random Forest är dess styrka att identifiera patienter med retinopati och har en betydligt lägre missfrekvens än SVM-RBF, däremot har modellen en tendens att skapa en bias mot den dominerande klassen. Styrkan med SVM-RBF är att den förhåller sig betydligt bättre till obalanserade klasser och generaliserar sig bättre till det mer obalanserade datasetet. Modellen har däremot en lägre precision och gav fler falskt positiva prediktioner när datasetet var mer balanserat.

Samtidigt visar intervjuerna att båda modellerna fortfarande ligger över den felmarginal som vårdpersonalen beskrev som acceptabel. Modellerna saknar även motivering vid prediktion som är ett krav för acceptans. Resultatet blir därför att modellerna har tydliga prediktiva styrkor samt svagheter, men att de inte kan användas i klinisk praxis eftersom de inte uppnår en acceptabel nivå.

Sammantaget visar resultaten att ingen av modellerna når den nivå av prestanda som beslutsfattare inom diabetesvården beskrev som kliniskt acceptabel, där en låg felmarginal och särskilt en låg missfrekvens efterfrågades för att modellen skulle uppfattas som tillförlitlig inom en klinisk kontext. Modellerna visade olika prestanda för de olika prediktionsproblemen, där Random Forest presterade bättre för retinopati och SVM-RBF presterade bättre för neuropati. Detta innebär att studiens resultat inte ger ett konkret svar, då modellerna inte är tillräckligt stabila för att kunna accepteras som ett beslutsstöd inom klinisk praxis.

Studien har däremot visat vilka krav som måste uppfyllas för att maskininlärning ska bli ett faktiskt kliniskt användbart beslutsstöd, snarare än enbart ett tekniskt fungerande prediktionsverktyg. För att modellerna ska kunna förbättras krävs därför mer balanserade datamängder, fler relevanta inmatningsvariabler, fortsatt validering samt utveckling av modeller som bättre kan stödja kliniska beslut utan att öka risken för missade fall eller falska positiva prediktioner.

7 Diskussion

I detta kapitel diskuteras studiens vetenskapliga bidrag, valda metoden, vetenskapliga reflektioner, samhälleliga och etiska aspekter samt förslag till fortsatt forskning.

7.1 Vetenskapligt bidrag och reflektion

Studiens huvudsakliga bidrag till forskningen är att skapa en koppling mellan den tekniska prestandan och kliniska acceptansen genom att kombinera modellresultat med intervjuer med beslutsfattare inom diabetesvården. Studien jämför därmed inte enbart modellernas numeriska prestanda, utan även kopplar det till identifierade acceptanskriterier. Genom att kombinera experimentell modellutvärdering med semi-strukturerade intervjuer visar studien hur maskininlärningsmodeller kan bedömas både tekniskt och kliniskt.

Studien skapar ett underlag för acceptanskriterier och vidare forskning för vad som krävs för att en modell ska vara relevant som beslutsstöd i klinisk praxis.

Vetenskapligt visar studien att prediktion av mikrovaskulära komplikationer hos typ 1-diabetiker är möjligt, men att det krävs mer än att enbart att välja en modell som presterar högt vid prestandamått. Resultaten för prediktion av retinopati och neuropati skiljde sig tydligt, vilket visar att olika komplikationer kan kräva olika modeller eller inmatningsvariabler. Ett stort problem med studien är det faktum att modellerna tränades på data som var obalanserad eftersom mycket av det datamaterial som samlades in från NDR innehöll saknade värden. För att uppnå en högre trovärdighet av studien användes olika tekniker såsom imputering för att fylla ut de värden som saknades och korsvalidering av hyperparametrar, vilket hjälpte för att öka modellernas prediktiva förmåga.

7.2 Metodreflektion

Studiens metod med experiment och semi-strukturerade intervjuer var lämplig eftersom den kvantitativa delen kunde visa modellernas prediktiva styrkor och svagheter, medan intervjuerna gav en klinisk kontext till resultatet. Experimentdelen passade väl eftersom syftet var att jämföra modellerna på samma datamaterial och därmed pröva vilken modell som presterade bäst för diabetisk retinopati och neuropati. Samtidigt visade arbetes genomförande att resultatet är starkt beroende av datamaterialets utformning och av de val som gjordes i bearbetningen av materialet.

En tydlig begränsning är att datasetet innehöll flera saknade värden och att neuropati datasetet var tydligt mer obalanserad än retinopati datasetet. Detta påverkade modellernas beteende, särskilt Random Forest som visade en hög missfrekvens och en tydlig bias mot den negativa klassen.

Om arbetet skulle göras om hade studien i stället börjat med semi-strukturerade intervjuer med beslutsfattare för att identifiera acceptanskriterier och relevant data för respektive mikrovaskulär komplikation. Detta hade möjliggjort att modellerna utvecklades

utifrån identifierade acceptanskriterier och med relevant data i experimentsdelen, vilket möjligtvis hade påverkat den kliniska acceptansnivån positivt.

7.3 Samhälleliga och etiska aspekter

Ur ett samhälleligt perspektiv är studien relevant eftersom tidig upptäckt av mikrovaskulära komplikationer kan minska risken för synnedläggelse, nervskador och ge diabetiker en bättre livskvalité som ligger i linje med studien av Lu et al. (2023). Studiens resultat visar att modellerna inte är tillräckligt träffsäkra för att användas inom en klinisk kontext eller utan en mänsklig bedömning av läkare. De prediktiva modellerna bör ses som ett stöd för screening eller prioritering av patienter och inte som en ersättning av läkare vid klinisk bedömning.

Etiskt bekräftar studien de risker som tidigare forskning lyfter kring felaktiga prediktioner, ansvar och tolkbarhet. Badawy et al. (2023) och Habehh & Gohel (2021) betonar att fel i sjukvården kan få allvarliga konsekvenser och att maskininlärning därför måste användas med tillsyn. En prediktiv modell utan tillsyn kan få stora konsekvenser inom hälso- och sjukvården.

Dessutom beskriver Grote & Berens (2020) att maskininlärnings algoritmer kan skapa ansvarsdilemman och defensiv medicin vilket medför hälsorisker för patienter. Detta ligger nära respondenternas syn på att en modell ska stödja, inte ersätta, vårdpersonal och att den slutgiltiga bedömningen ligger hos läkaren. Däremot nämner Grote & Berens (2020) att implementering av maskininlärning som beslutsstöd kan skapa osäkerhet bland kliniker, vilket kan leda till försämrade medicinska diagnoser.

7.4 Förslag till fortsatt forskning

Vidare forskning bör i första hand fokusera på att förbättra modellernas kliniska användbarhet och acceptansnivå. Detta skulle kunna innebära att inkludera fler beslutsfattare inom diabetesvården för att skapa en bredare bild av acceptanskriterier, samt identifiera inmatningsvariabler som passar bättre för de olika komplikationerna. Test med andra modeller och använda andra metoder för att hantera klassobalans är även relevant vid vidare forskning.

Studiens viktigaste begränsning är att resultatet påverkas av det tillgängliga materialets kvalitet, innehåll och obalans. Datamaterialet visade en tydlig obalans mellan de olika klasserna, vilket sannolikt bidrog till att Random Forest-modellen fick en mycket hög missfrekvens för neuropati. Vidare forskning bör därför även undersöka om en bättre balans i datamaterialet, fler prediktiva och relevanta variabler eller andra prediktiva modeller kan förbättra resultatet.

Referenser

- Badawy, M., Ramadan, N., & Hefny, H. A. (2023). Healthcare predictive analytics using machine learning and deep learning techniques: A survey. *Journal of Electrical Systems and Information Technology*, 10(1), 40. <https://doi.org/10.1186/s43067-023-00108-y>
- Creswell, J. W. (2014). *Research design: Qualitative, quantitative, and mixed methods approaches* (4. ed). SAGE.
- Dagliati, A., Marini, S., Sacchi, L., Cogni, G., Teliti, M., Tibollo, V., De Cata, P., Chiovato, L., & Bellazzi, R. (2018). Machine Learning Methods to Predict Diabetes Complications. *Journal of Diabetes Science and Technology*, 12(2), 295–302. <https://doi.org/10.1177/1932296817706375>
- Du, Z., Liu, X., Li, J., Min, H., Ma, Y., Hua, W., Zhang, L., Zhang, Y., Shang, M., Chen, H., Yin, H., & Tian, L. (2025). Development and external validation of a machine learning model to predict diabetic nephropathy in T1DM patients in the real-world. *Acta Diabetologica*, 62(6), 869–879. <https://doi.org/10.1007/s00592-024-02404-z>
- Eckardt, J.-N., Bornhäuser, M., Wendt, K., & Middeke, J. M. (2022). Semi-supervised learning in cancer diagnostics. *Frontiers in Oncology*, 12, 960984. <https://doi.org/10.3389/fonc.2022.960984>
- Emmert-Streib, F., Yli-Harja, O., & Dehmer, M. (2020). Artificial Intelligence: A Clarification of Misconceptions, Myths and Desired Status. *Frontiers in Artificial Intelligence*, 3. <https://doi.org/10.3389/frai.2020.524339>
- Fife, D. A., & D'Onofrio, J. (2023). Common, uncommon, and novel applications of random forest in psychological research. *Behavior Research Methods*, 55(5), 2447–2466. <https://doi.org/10.3758/s13428-022-01901-9>
- Ganesan, J., Krishnan, V., Rathinavel, T., Shalini, K. S., Selvankumar, T., Gomathi, M., Maheswari, S. U., & Ameer, K. (2025). Enhancing breast cancer detection accuracy through machine learning, deep learning and transfer learning techniques for clinical practice. *Discover Artificial Intelligence*, 6(1), 29. <https://doi.org/10.1007/s44163-025-00649-3>

- Géron, A. (2019). *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems* (Second edition). O'Reilly.
- Grote, T., & Berens, P. (2020). On the ethics of algorithmic decision-making in healthcare. *Journal of Medical Ethics*, 46(3), 205–211. <https://doi.org/10.1136/medethics-2019-105586>
- Habebh, H., & Gohel, S. (2021). Machine Learning in Healthcare. *Current Genomics*, 22(4), 291–300. <https://doi.org/10.2174/1389202922666210705124359>
- Integritetsskyddsmyndigheten. (2025, June 11). *Introduktion till dataskyddsförordningen*. <https://www.imy.se/verksamhet/dataskydd/det-har-galler-enligt-gdpr/introduktion-till-gdpr>
- Jiang, T., Gradus, J. L., & Rosellini, A. J. (2020). Supervised Machine Learning: A Brief Primer. *Behavior Therapy*, 51(5), 675–687. <https://doi.org/10.1016/j.beth.2020.05.002>
- Kanbour, S., Harris, C., Lalani, B., Wolf, R. M., Fitipaldi, H., Gomez, M. F., & Mathioudakis, N. (2024). Machine Learning Models for Prediction of Diabetic Microvascular Complications. *Journal of Diabetes Science and Technology*, 18(2), 273–286. <https://doi.org/10.1177/19322968231223726>
- Kapa, M., Koryciarz, I., Kustosik, N., Jurowski, P., & Pniakowska, Z. (2024). Modern Approach to Diabetic Retinopathy Diagnostics. *Diagnostics*, 14(17), 1846. <https://doi.org/10.3390/diagnostics14171846>
- Li, X., Sigov, A., Ratkin, L., Ivanov, L. A., & Li, L. (2023). Artificial intelligence applications in finance: A survey. *Journal of Management Analytics*, 10(4), 676–692. <https://doi.org/10.1080/23270012.2023.2244503>
- Li, Y., Jin, N., Zhan, Q., Huang, Y., Sun, A., Yin, F., Li, Z., Hu, J., & Liu, Z. (2025). Machine learning-based risk predictive models for diabetic kidney disease in type 2 diabetes mellitus patients: A systematic review and meta-analysis. *Frontiers in Endocrinology*, 16, 1495306. <https://doi.org/10.3389/fendo.2025.1495306>
- Lu, Y., Wang, W., Liu, J., Xie, M., Liu, Q., & Li, S. (2023). Vascular complications of diabetes: A narrative review. *Medicine*, 102(40), e35285.

<https://doi.org/10.1097/MD.00000000000035285>

Maniruzzaman, Md., Islam, Md. M., Rahman, Md. J., Hasan, Md. A. M., & Shin, J. (2021). Risk prediction of diabetic nephropathy using machine learning techniques: A pilot study with secondary data. *Diabetes & Metabolic Syndrome: Clinical Research & Reviews*, *15*(5), 102263. <https://doi.org/10.1016/j.dsx.2021.102263>

Mukhamediev, R. I., Popova, Y., Kuchin, Y., Zaitseva, E., Kalimoldayev, A., Symagulov, A., Levashenko, V., Abdoldina, F., Gopejenko, V., Yakunin, K., Muhamedijeva, E., & Yelis, M. (2022). Review of Artificial Intelligence and Machine Learning Technologies: Classification, Restrictions, Opportunities and Challenges. *Mathematics*, *10*(15), 2552. <https://doi.org/10.3390/math10152552>

Ofosu-Ampong, K. (2024). Artificial intelligence research: A review on dominant themes, methods, frameworks and future research directions. *Telematics and Informatics Reports*, *14*, 100127. <https://doi.org/10.1016/j.teler.2024.100127>

Ogle, G. D., Wang, F., Haynes, A., Gregory, G. A., King, T. W., Deng, K., Dabelea, D., James, S., Jenkins, A. J., Li, X., Ma, R. C. W., Maahs, D. M., Oram, R. A., Pihoker, C., Svensson, J., Zhou, Z., Magliano, D. J., & Maniam, J. (2025). Global type 1 diabetes prevalence, incidence, and mortality estimates 2025: Results from the International diabetes Federation Atlas, 11th Edition, and the T1D Index Version 3.0. *Diabetes Research and Clinical Practice*, *225*, 112277. <https://doi.org/10.1016/j.diabres.2025.112277>

Panzer, M., & Bender, B. (2022). Deep reinforcement learning in production systems: A systematic literature review. *International Journal of Production Research*, *60*(13), 4316–4341. <https://doi.org/10.1080/00207543.2021.1973138>

Partanen, J., Niskanen, L., Lehtinen, J., Mervaala, E., Siitonen, O., & Uusitupa, M. (1995). Natural History of Peripheral Neuropathy in Patients with Non-Insulin-Dependent Diabetes Mellitus. *New England Journal of Medicine*, *333*(2), 89–94. <https://doi.org/10.1056/NEJM199507133330203>

Pichler, M., & Hartig, F. (2023). Machine learning and deep learning—A review for ecologists. *Methods in Ecology and Evolution*, *14*(4), 994–1016. <https://doi.org/10.1111/2041-210X.14061>

- Quattrin, T., Mastrandrea, L. D., & Walker, L. S. K. (2023). Type 1 diabetes. *The Lancet*, 401(10394), 2149–2162. [https://doi.org/10.1016/S0140-6736\(23\)00223-4](https://doi.org/10.1016/S0140-6736(23)00223-4)
- Sarker, I. H. (2021). Machine Learning: Algorithms, Real-World Applications and Research Directions. *Sn Computer Science*, 2(3), 160. <https://doi.org/10.1007/s42979-021-00592-x>
- Singh, A., Shadangi, S., Gupta, P. Kr., & Rana, S. (2025). Type 2 Diabetes Mellitus: A Comprehensive Review of Pathophysiology, Comorbidities, and Emerging Therapies. *Comprehensive Physiology*, 15(1), e70003. <https://doi.org/10.1002/cph4.70003>
- Sukri, N. F. A. A., Hamzah, W. M. A. F. W., Yusof, M. K., Ismail, I., Yusoff, H. M., & Yacob, A. (2025). A Systematic Literature Review on Machine Learning in Healthcare Prediction. *International Journal of Online and Biomedical Engineering (ijOE)*, 21(06), 155–177. <https://doi.org/10.3991/ijoe.v21i06.54211>
- van Engelen, J. E., & Hoos, H. H. (2020). A survey on semi-supervised learning. *Machine Learning*, 109(2), 373–440. <https://doi.org/10.1007/s10994-019-05855-6>
- Vetenskapsrådet. (2018, December 10). *Etik i forskningen och god forskningssed*. <https://www.vr.se/uppdrag/etik/etik-i-forskningen.html>
- Wohlin, C., Runeson, P., Höst, M., Ohlsson, M. C., Regnell, B., & Wesslén, A. (2012). *Experimentation in Software Engineering*. Springer. <https://doi.org/10.1007/978-3-642-29044-2>