

AI-baserad fastighetsvärdering av småhus

Funktion, utmaningar och etiska begränsningar

Movitz Ahlfors
Anton Ladan

Civilingenjör i Lantmäteri
VFTM01 Examensarbete i fastighetsvetenskap
Fastighetsekonomi

© Movitz Ahlfors & Anton Ladan, 2026

Båda författarna har gemensamt bidragit till hela examensarbetet.

Fastighetsvetenskap, Institution för teknik och samhälle
Lunds Tekniska Högskola, Lunds universitet
Box 118
221 00 Lund

ISRN LUTVDG/TVLM 26/5604SE
Tryckort: Lund

AI-baserad fastighetsvärdering av småhus

AI-based property valuation of single-family homes

Examensarbete utfört av/Master of Science Thesis by:

Movitz Ahlfors, Civilingenjörsutbildning i Lantmäteri, LTH, Lunds universitet
Anton Ladan, Civilingenjörsutbildning i Lantmäteri, LTH, Lunds universitet

Handledare/Supervisor:

Ingemar Bengtsson, Universitetslektor, Fastighetsvetenskap, LTH, Lunds universitet

Examinator/Examiner:

James White, Forskare i AI och samhälle, Fastighetsvetenskap, LTH, Lunds universitet

Opponent/Opponent:

Isac Malmström, Civilingenjörsutbildning i Lantmäteri, LTH, Lunds universitet
Milan Terzija, Civilingenjörsutbildning i Lantmäteri, LTH, Lunds universitet

Nyckelord: AI, AI-baserad fastighetsvärdering, AI-modell, Datadriven analys, Etik, Fastigheter, Fastighetsvärdering, Maskininlärning, Prestandautvärdering, Samhällspåverkan, Småhus, XGBoost

Keywords: AI, AI-based property valuation, AI-model, Data-driven analysis, Ethics, Machine learning, Performance evaluation, Properties, Property valuation, Real estate valuation, Single-family homes, Societal impact, XGBoost

Förord

Detta examensarbete har genomförts som en avslutande del av civilingenjörsutbildningen i lantmäteri vid Lunds tekniska högskola.

Vi vill främst ge ett stort tack till Lantvägen, som under studietiden varit en central samlingsplats och ett ställe att ibland fokusera och främst träffas på. Det är i efterhand svårt att se hur utbildningen skulle ha kunnat genomföras utan Lantvägen. Där har många problem lösts, uppgifter diskuterats och motivationen hållits uppe.

Vidare vill vi tacka vår handledare för hans stöd och feedback samt för det förtroende han visade oss att kunna genomföra ett arbete av denna typ.

Slutligen vill vi tacka familj och vänner för stöd och uppmuntran under studietiden.

Movitz Ahlfors & Anton Ladan

Abstract

This study examines the development and performance of an AI-based valuation model for Swedish single-family houses. The aim is to analyse how such models function, identify key development challenges, and assess associated ethical and societal implications.

A proprietary model, Movton, was developed using the XGBoost algorithm and trained on over 600 000 housing transactions in Sweden from 2018 to 2026. The dataset was enriched with geocoded locations, macroeconomic indicators, and temporal features. To enhance interpretability, SHAP values were applied, allowing each prediction to be decomposed into variable-level contributions. The model achieved a Median Absolute Percentage Error of 13 percent and an r^2 of 0.871, explaining approximately 87 percent of price variation. Temporal validation confirmed stable performance over time. Comparisons with established models showed similar accuracy, with median deviations around 9 percent. Key challenges were primarily data-related, including data quality issues, non-market transactions, risk of data leakage, and limited information on property conditions. The nationwide scope also contributed to higher error levels than a regional model might produce. From an ethical perspective, risks include reinforcing existing market biases, reduced accountability due to model opacity, and privacy concerns linked to data usage. Model homogenisation and labour market polarisation are sometimes presented as systemic risks, but the practical obstacles identified here, particularly around data and metadata quality, suggest such outcomes are gradual rather than imminent. The findings suggest that AI-based valuation is feasible, but hybrid approaches combining human expertise remain the most robust in practice.

Sammanfattning

Detta examensarbete undersöker utvecklingen och prestandan hos en AI-baserad värderingsmodell för svenska småhus. Arbetet syftar till att analysera hur AI-baserade värderingsmodeller fungerar, vilka utmaningar som uppstår vid deras skapande, samt vilka etiska och samhällsmässiga begränsningar som förknippas med deras användning.

Som metod har en egen värderingsmodell utvecklats med hjälp av maskininlärningsalgoritmen XGBoost, tränad på över 600 000 småhusförsäljningar i Sverige under perioden 2018-2026. Data hämtades från Värderingsdata och kompletterades med geokodade koordinater, makroekonomiska variabler, lokala prisankare och tidsrelaterade variabler. För att säkerställa transparens och förklarbarhet implementerades SHAP-värden (SHapley Additive exPlanations), vilket möjliggör en nedbrytning av varje enskild prediktion i additiva bidrag per variabel. Modellen namngavs Movton. Den slutliga modellen uppnådde ett MdAPE på 13 procent och ett r^2 -värde på 0,871 på testdata, vilket innebär att modellen förklarar cirka 87 procent av variationen i försäljningspriser. Resultaten från den temporala korsvalideringen bekräftade att modellen är stabil över tid. En jämförelse med etablerade referensmodeller, Boolis AVM och Värderingsdatas prisindikator, visade att modellen presterar i ett liknande spann med ett MdAPE på 8,7 procent respektive 9,5 procent mot dessa. De största utmaningarna i modellutvecklingen visade sig ligga utanför det algoritmiska valet och rörde primärt datakvalitet, hantering av icke-marknadsmässiga transaktioner, skydd mot dataläckage samt begränsad tillgång till variabler som beskriver fastighetens faktiska skick. Därtill bidrog modellens nationella täckning till en högre felmarginal jämfört med vad en regionalt avgränsad modell sannolikt hade uppnått. Från ett etiskt och samhällsmässigt perspektiv identifieras flera centrala utmaningar. AI-modeller riskerar att reproducera och befästa historisk strukturell diskriminering i bostadsmarknaden via proxyvariabler. Modellhomogenisering, där flera aktörer använder strukturellt liknande modeller tränade på överlappande data, lyfts i tidigare forskning som ett hot mot den finansiella stabiliteten, men arbetets egna erfarenheter talar för att sådan konvergens kräver samstämmighet i ett stort antal modelleringsval och inte enbart delad data, vilket gör risken mer villkorad än omedelbar. Vidare försvårar *black box*-problematiken ansvarsskyldighet och rättssäkerhet, och moderna datainsamlingstekniker väcker frågor om personlig integritet. Arbetsmarknadsmässigt beskrivs värderingsyrket ofta som hotat av polarisering, men de datakvalitetsproblem och det behov av fastighetsspecifik bedömning som arbetet visar pekar snarare mot en gradvis omdefiniering av yrkesrollen mot hybridarbete än mot en snabb automatisering av mellanskiktet.

Sammantaget visar arbetet att det inom ramen för begränsade resurser är möjligt att bygga en AI-baserad värderingsmodell med rimlig prediktiv förmåga. Hybridmodeller, där AI kombineras med mänsklig expertis, framstår som det mest realistiska och robusta tillvägagångssättet i närtid. En etiskt legitim implementering förutsätter dock inte enbart algoritmisk kapacitet, utan i lika hög grad institutionella, juridiska och normativa ramverk.

Innehållsförteckning

1	Inledning	1
1.1	Bakgrund	1
1.2	Syfte	3
1.3	Frågeställning	4
1.4	Avgränsningar	4
1.5	Bakomliggande begrepp	4
1.5.1	Förkortningar	4
1.5.2	Relation mellan AI-baserade metoder	4
1.6	Metod	5
1.7	Disposition	5
2	AI-Deklaration	7
3	Tidigare forskning	9
3.1	Mänskliga värderingsbrister och jämförelse med AI-baserade modeller	9
3.2	Integrationen av AI och mänsklig värdering i praktiken	10
3.3	AI i fastighetsvärdering: rättvisa, transparens och finansiella risker	11
4	Explainable AI (XAI)	13
4.0.1	XGBoost	13
4.0.2	Målfunktionen	15
4.0.3	Överanpassning	16
4.0.4	Underanpassning	16
4.0.5	SHAP-värden	16
4.0.6	Fördjupning av black-box problematiken	17
5	Modellexperiment	18
5.1	Valet av XGBoost som AI-modell	18
5.2	Datakälla	18
5.3	Målvariabel och träningsprincip	19
5.4	Inledande prototyparbete	20
5.5	Första modelliteration - regional prototyp	20
5.6	Geokodning av fastighetsdata	21
5.7	Beslut om nationell modell och dataurval	21
5.8	Datainsamling	22
5.9	Databearbetning och kvalitetssäkring	23
5.9.1	Sammanslagning, borttagning av dubletter och sammanslagning	23
5.9.2	Hantering av semikolonseparerade cellvärden	23
5.9.3	Borttagning av grova outliers	24
5.10	Geokodning av det nationella datasetet	25
5.10.1	Behovet av koordinater	25
5.10.2	Skalningsutmaning och alternativanalys	25
5.10.3	Anpassning av geokodningsskriptet för långvarig drift	26

5.10.4	Validering av koordinater	26
5.11	Kategorisk kodning	28
5.12	Tidsrelaterade variabler	29
5.13	Avstånd till centralort	30
5.14	Makroekonomiska variabler	30
5.15	Lokala prisankare	31
5.15.1	Tidsjustering med SCB:s prisindex	31
5.15.2	Area_Median_m2, distriktets medianpris	32
5.15.3	KNN_Price_m2, grannskapsbaserat prisankare	32
5.15.4	Prev_Sale_Price och Prev_Sale_Months_Ago, försäljningsvariablerna	33
5.15.5	Varför normalisering behövs trots tidsvariabler	33
5.16	Hantering av icke-marknadsmässiga försäljningar	34
5.16.1	Filtrering baserat på K/T-kvot	35
5.16.2	Justering av KNN-beräkningen	35
5.17	Logaritmisk transformering av målvariabeln	35
5.18	Modellträning och validering	36
5.18.1	Hyperparametrar	36
5.18.2	Temporal walk-forward korsvalidering	37
5.18.3	Slutmodell	38
5.18.4	Från slumpmässig split till temporal validering	38
5.18.5	Hantering av Prev_Sale_Price	38
5.19	SHAP - förklarbarhet och transparens	38
5.19.1	Lokal SHAP	38
5.19.2	Global SHAP	39
5.19.3	Kollinearitetsanalys och variabelreducering	39
5.19.4	Transparensrapport	40
5.20	Användargränssnitt	41
5.20.1	Prognosflödet	41
5.20.2	Tweaka och byt datum: iterativ utforskning	42
5.20.3	SHAP-analys: slå på transparensen	42
5.20.4	Kompletterande datainsamling	42
5.20.5	Lyxmodell och mjuk övergång	43
6	Resultat	45
6.1	Modellens variabler	45
6.2	Hyperparametrar	47
6.3	Modellprestanda	47
6.4	Korsvalidering	47
6.5	Lokal SHAP och transparensrapport	48
6.6	Global SHAP-analys	52
6.7	Värdering av enskilda fastigheter: två stickprov	54
6.7.1	Referensmodeller	54
6.7.2	Stickprov 1: jämförelse mot Booli och Värderingsdata	56
6.7.3	Stickprov 2: rent prediktiv utvärdering	59
7	Diskussion	62

7.1	Hur fungerar AI-baserade värderingsmodeller?	62
7.2	Vilka utmaningar finns i skapandet av AI-baserade värderingsmodeller?	64
7.3	Vilka är de etiska och samhällsmässiga begränsningarna med att använda AI-baserad fastighetsvärdering?	68
7.3.1	Sammanfattning	68
7.3.2	Algoritmisk rättvisa och reproduktion av strukturell diskriminering	69
7.3.3	Systemrisk, modellhomogenisering och finansiell stabilitet	72
7.3.4	Transparens, ansvarsskyldighet och rättssäkerhet	73
7.3.5	Integritet och datainsamling i en digitaliserad värderingsprocess	74
7.3.6	Arbetsmarknad, yrkesroller och social omställning	75
8	Slutsats	77
9	Källor	79

1 Inledning

I det inledande kapitlet presenteras en bakgrund till varför AI-baserad fastighetsvärdering har blivit intressant. Ytterlig beskrivs syftet och frågeställningarna som har varit till grund för examensarbetet.

1.1 Bakgrund

Under de senaste fem åren har artificiell intelligens (AI) genomgått en omfattande utveckling. De tekniska genombrotten som gjort AI möjligt har skett successivt i takt med att tillgången till stora datamängder blivit bättre och framförallt förbättrad beräkningskapacitet (Sevilla m. fl. 2022), allt stött av tekniska framsteg inom maskinvarubranschen (Hooker 2020). Detta har resulterat i allt mer avancerade AI-modeller. De har blivit allt bättre på att bland annat analysera datamängder, identifiera mönster, och göra prediktioner (Jordan och Mitchell 2015). Dessa tidigare modeller har oftast varit låsta bakom stängda API:er för utvecklare (Bommasani m. fl. 2021). AI fick emellertid sitt stora kulturella genombrott för allmänheten i slutet av November 2022 när OpenAI lanserade sin generativa språkmodell (LLM) ChatGPT-3.5 (Dwivedi m. fl. 2023). Medvetenheten och generella förståelsen för generativ AI och dess potential har sedan dess bara ökat och AI har integrerats i allt fler tjänster, verksamheter och applikationer (Brynolfsson, Li och Raymond 2023).

Fastighetsbranschen, som är karakteristiskt institutionellt trög, har också likt resten av samhället börjat integrera AI i allt större utsträckning. Integration har skett både på konsument- och producentsidan. Konsumenter har i allt större utsträckning börjat använda sig av smarta hem lösningar, en trend som förväntas öka då marknaden för smarta hem-lösningar uppskattas att växa med 26 % till och med 2030 inom Europa (Grand View Research 2025). Även faktorer som att digitala lås numera dominerar vid nyinstallation i Sverige (Kante 2024) är indikativt för AIs trender på konsumentensidan. Företag har emellertid också börjat integrera AI-verktyg och system i deras dagliga verksamhet. Denna trend började redan under pandemin då 60 % av fastighetsföretagen uppgav att de hade ökat sin användning av branschspecifika digitala hjälpmedel som ett direkt svar på coronapandemin (Svensk Byggtjänst 2021). Utvecklingen av tekniska lösningar inom fastighetsbranschen har fortsatt och dagsläget används tekniken främst för att implementera smarta och hållbara fastigheter genom centraliserade system för analysering av energianvändning och elbehov och ventilation (Nordlo 2024). Fastighetsvärdering har traditionellt utförts med redan etablerade metoder. Dessa metoder varierar från till exempel ortsprismetoden till avkastningsmetoden och produktionskostnadsmetoden beroende på omständigheter och typ av fastighet (Lind 2014; Bengtsson 2023). Traditionella värderingsmetoder har dock gemensamt att de alla bygger på historiska transaktioner, kassaflödesberäkningar (International Valuation Standards Council 2021) och framförallt en värderares professionella omdöme (Wyman, Seldin och Worzala 2011). Under senare år har dock automatiserade värderingsmodeller (AVM) fått större betydelse.

Tidiga AVM-system bygger på hedoniska regressionsmodeller. Dessa hade en förmåga förklara ett fastighetspris som en funktion av observerbara attribut som till exempel boyta, byggnadsår och läge (Freeman III, Herriges och Kling 2014, s. 79). Men i takt med att tekniken har utvecklats, genom att datamängderna har ökat, beräkningskapaciteten förbättrats och mer avancerade maskinlärningsmetoder implementerats, har också AVM-landskapet utvecklats. Detta på grund av att, särskilt djupinlärningsmodeller, har visat en förmåga att kunna hantera mångdimensionella icke-linjära samband i större datamängder. (Erciyes m. fl. 2025, s. 2). djupinläring som bygger på flerskiktade neurala nätverk kan identifiera och kvantifiera samband mellan flera variabler i komplexa flerdimensionella datamängder utan att deras relation specificeras i förväg (Erciyes m. fl. 2025, s. 13). Inom fastighetsvärdering kan detta till exempel innebära att en AI-baserad fastighetsvärderingsmodell identifierar subtila samband och mönster kopplade till socioekonomiska faktorer, närheten till infrastruktur eller andra makroekonomiska trender. I kombination med mer traditionella transaktionsdata kan detta leda till bättre prediktioner av fastighetspriser (Valier 2020, s. 221), särskilt på heterogena marknader, exempelvis småhusfastigheter.

Problemen med användningen av AI vid fastighetsvärdering är dock att många av dess system använder sig av en så kallad Black box. Black box är något som förekommer både i djupa neurala nätverk och maskinlärningsmetoder. En black box innebär att modellens interna beslutsprocess blir i princip omöjlig att förstå då den byggs upp av ett stort antal icke-linjära transformationer och viktningar som optimeras under träningsprocessen. Detta betyder att modellen, även om den uppvisar hög prediktiv prestanda, inte kan förklara hur alla variabler påverkar (Burrell 2016, s. 10). Sett ur många användningsperspektiv skiljt från fastighetsvärdering hade detta inte varit ett problem då det inte finns väsentligt behov för en användare att varken förstå eller behöva granska en AIs slutledningsförmåga. Men sett till fastighetsvärdering formas ett problem specifikt sett till modellens transparens, spårbarhet (Samek, Wiegand och Müller 2017) och både en utgivare och användares professionella ansvar (Ribeiro, Singh och Guestrin 2016).

Det bör dock understrykas att dessa problem är olika akuta beroende på vilken typ av AI-metod som avses. De är som mest påtagliga för djupa neurala nätverk och metoder baserade på så kallad unsupervised learning, där modellens inre logik är särskilt svårgenomtränglig och utvecklingen gått snabbt under senare år. För enklare och mer etablerade maskininlärningsmetoder, som bygger på supervised learning och strukturerad data, är problematiken mindre uttalad, även om den inte är frånvarande. Hur dessa frågor förhåller sig till den metod som används i detta arbete utvecklas vidare i senare kapitel.

En annan problematisk aspekt rörande AI inom fastighetsvärdering handlar om beteendet hos människor, mer specifikt beteendeekonomiska aspekter. Traditionella fastighetsvärderingar kommer påverkas av mänskliga bedömningar och därmed även beteendeekonomiska mönster såsom ankereffekt, flockbeteende och överkonfians (Birkeland m. fl. 2021). Detta är något som inte bara kommer påverka en värderare utan andra marknadsaktörer, däribland säljare och köpare

(Topraklı 2024). Beteendeeconomiska trender är i princip omöjliga att kvantifiera och modellera både sett till historiska försäljningar, som utgör basen för all träningsdata, och sett till framtida försäljningar, där en ”mänsklig residual” alltid kommer att kvarstå och påverka det faktiska priset. Detta medför både problemet att modellen reproducerar historisk marknadsineffektivitet som idag inte är aktuell och oförmågan att extrapolera framtidens marknadsineffektivitet som påverkar det faktiska priset (Teikari m. fl. 2025). Så trots att en AI-baserad modell kan bidra till att minska individuella *bias* genom systematiskt datadrivna analyser så saknar den en mänsklig slutledningsförmåga att kunna fånga diskreta trender som omöjligt kan fångas av träningsdata (Teikari m. fl. 2025, s. 2).

Fastighetsmarknaden och specifikt fastighetsvärde befinner sig i ett paradigmskifte. Utvecklingar inom artificiell intelligens har medfört möjligheten till skalbara och träffsäkra värderingsmodeller, särskilt på heterogena marknader. Därmed har traditionella värderingsmetoder som historiskt bygger på ortspriser, kassaflöden och enskilda värderares omdöme börjat utmanas. Den teknologiska utvecklingen som möjliggjort bättre och bättre bearbetning av allt större och mer komplexa datamängder har revolutionerat automatiserade värderingsmodeller. De kan inte längre bara identifiera linjära samband mellan olika attribut utan även identifiera icke-linjära diskreta samband mellan flera variabler och attribut vilket kan leda till högre prediktiv precision och snabbare värderingsprocesser. Trots detta kvarstår problem och utmaningar rörande modellens låga transparens vilket påverkar spårbarhet, tillit och ansvar samt faktumet att fastighetsmarknaden bygger på mänskligt beteende vilket medför risker att socioekonomiska trender replikeras istället för att korrigeras i modellen. Det medför att problemen måste hanteras både teknologiskt och institutionellt då fastighetsvärderingar ligger till grund för finansiella beslut av stor ekonomisk betydelse.

1.2 Syfte

Syftet med arbetet är att analysera hur AI-baserade värderingsmodeller för småhus fungerar och vilka utmaningar som uppstår vid utvecklingen av en sådan modell. Som ett led i detta utvärderas även modellens prediktiva prestanda, dels genom statistiska mått, dels genom en jämförelse med etablerade referensmodeller. Arbetet ämnar vidare att belysa de etiska och samhällsmässiga begränsningar som är förknippade med användningen av AI-baserade värderingsinstrument, med fokus på transparens, rättssäkerhet och möjliga konsekvenser för marknadens aktörer.

1.3 Frågeställning

Arbetet ämnar till att besvara tre frågeställningar rörande AI-baserad fastighetsvärdering. Frågeställningarna lyder som följande.

1. Hur fungerar AI-baserade värderingsmodeller?
2. Vilka utmaningar finns i skapandet av AI-baserade värderingsmodeller?
3. Vilka är de etiska och samhällsmässiga begränsningarna med att använda AI-baserad fastighetsvärdering?

1.4 Avgränsningar

Vi ämnar enbart att undersöka våra frågeställningar i relation till fastighetsmarknaden för småhus. Anledningen till enbart småhus valdes är för att marknaden för småhus är hyfsat homogen till skillnad från kommersiella fastigheter. Lägenheter å andra sidan valdes bort på grund av tidsbegränsningar som inte hade möjliggjort hanteringen av både småhus och lägenheter samtidigt. Dessa två marknadssegment valdes dessutom bort då tillgängligheten av information, särskilt kvalitativ information, bedömdes som sämre. Återigen bedömdes omständigheterna för kommersiella fastigheter som särskilt försvårade då det inte finns någon form av enhetlig information samt hög variation mellan enskilda objekt.


1.5 Bakomliggande begrepp

1.5.1 Förkortningar

AI - Artificiell intelligens
AVM - Automated valuation model
XGBoost - Extreme Gradient Boosting
MdAPE - Median Absolute Percentage Error
XAI - Explainable AI
SHAP - SHapley Additive exPlanations
LLM - Large language model
ML - Maskinlärning
NN - Neural network
DL - Deep learning

1.5.2 Relation mellan AI-baserade metoder

Då studien behandlar flera relaterade tekniker inom artificiell intelligens presenteras en konceptuell översikt i figur 1. Figuren visar hur områdena inom artificiell intelligens förhåller sig till varandra.



Figur 1: Visar flödet av indata (Konceptuell hierarkisk struktur över AI-baserade metoder och deras relation till varandra. Källa: Egen framställning.

1.6 Metod

Arbetets första två frågeställningar besvaras genom ett modellexperiment. Inom ramen för begränsade resurser och den tid som exjobbskursen medger utvecklas en egen AI-baserad värderingsmodell för småhus. Genom att praktiskt genomföra detta experiment identifieras och analyseras de utmaningar som uppstår vid skapandet av en sådan modell. Modellens prediktiva prestanda utvärderas sedan mot etablerade referensmodeller.

Den tredje frågeställningen besvaras genom en litteraturstudie där tidigare relevant forskning och rapporter inom området analyseras, kompletterat med insikter från modellexperimentet.

1.7 Disposition

Inledning

Studien inleds med en generell beskrivning om området vi berör, närmare bestämt fastighetsvärdering och artificiell intelligens. Inledningen ämnar att underlätta för en läsare att förstå AIs utveckling, dess användning i fastighetsbranschen samt problematik kring ytterligare adaption inom branschen. Kapitlet innehåller även syfte, frågeställningar, avgränsningar, en introduktion till bakomliggande begrepp inom artificiell intelligens samt en övergripande beskrivning av arbetets metod.

AI-Deklaration

Redogör transparent för hur AI har använts inom ramen för arbetet, i vilken omfattning det använts samt vilka begränsningar och ansvarsförhållanden som föreligger. Syftet är att säkerställa transparens kring AI-användningen i både den teoretiska och praktiska delen av arbetet.

Tidigare forskning

Presenterar en litteraturstudie av tidigare forskning inom området AI-baserad fastighetsvärdering. Kapitlet behandlar mänskliga värderingsbrister och jämför dessa med AI-baserade modeller, integrationen av AI och mänsklig värdering i praktiken samt de etiska, juridiska och samhällseliga utmaningar som AI-baserad fastighetsvärdering medför.

Explainable AI, XGBoost

Innehåller en övergripande beskrivning om hur explainable AI fungerar samt vilka problem explainable AI löser samt teori om hur XGBoost är uppbyggt och varför XGBoost valdes som verktyg i skapandet av fastighetsvärderings AI:n.

Modellexperiment

Beskriver det experiment genom vilket arbetets första två frågeställningar besvaras, nämligen utvecklingen av en egen AI-baserad värderingsmodell. Kapitlet redogör steg för steg för datainsamling, databearbetning, geokodning, konstruktion av variabler, modellträning och validering samt det grafiska användargränssnittet.

Resultat

Presenterar den slutliga modellens uppbyggnad och prestanda, inklusive modellens variabler, hyperparametrar och statistiska nyckeltal från testdata samt resultat från den temporala korsvalideringen. Kapitlet innehåller även en jämförelse mellan modellens värderingar och faktiska försäljningspriser för två stickprov av fastighetsobjekt, samt en jämförelse med referensmodeller.

Diskussion

Besvarar arbetets tre frågeställningar. Inledningsvis behandlas hur AI-baserade värderingsmodeller fungerar tekniskt och prestationsmässigt, samt möjligheten till hybridmodeller. Därefter diskuteras de utmaningar som uppstod under utvecklingen av modellen, däribland datainsamling, geokodning och hantering av icke-marknadsmässiga försäljningar. Avslutningsvis analyseras de etiska och samhällsmässiga begränsningarna med AI-baserad fastighetsvärdering, med fokus på algoritmisk rättvisa, systemrisk, transparens, integritet och arbetsmarknadspåverkan.

Slutsats

Sammanfattar arbetets viktigaste slutsatser i relation till de tre frågeställningarna och diskuterar AI-värderingens etiska legitimitet och samhällseliga konsekvenser.

2 AI-Deklaration

Nedan beskrivs användningen av artificiell intelligens inom arbetet, specifikt dess användning för att producera innehåll, analyser, slutsatser och eventuella beslut. Syftet med en AI deklARATION är att skapa transparens kring hur vi har använt AI, i vilken omfattning vi har använt AI, samt vilka begränsningar och ansvar som föreligger användningen av AI.

Användning av AI i projektet

AI har inom ramen för den teoretiska delen av arbetet framförallt använts som ett stödverktyg och i begränsad utsträckning. AI har framförallt använts som språkligt stöd främst i form av ett verktyg att generera förslag på hur textstycken kan formuleras, hjälp med omformuleringar samt som granskning för att hålla en hög läsbarhet. AI har dessutom använts för att effektivare kunna hitta en stor kvantitet av akademiska källor. Samtliga resonemang, slutsatser, granskning av källor samt tolkning av källor har dock genomförts självständigt av oss författare.

Inom ramen för den praktiska delen av arbetet, där en AI-modell för fastighetsvärdering har utvecklats, har AI-baserade verktyg använts i större utsträckning. AI har primärt använts för till exempel generering av kodförslag, felsökning av kod samt för effektivisering av utvecklingsprocessen. Övergripande design av modellen, val av metod och implementeringsbeslut har dock tagits självständigt av oss författare.

All information som genererats med hjälp av AI har granskats kritiskt. Detta då det finns en icke obetydlig risk för felaktigheter och föråldrad information. AI har tendenser att både "hallucinera" och hitta på icke-befintliga svar samt presentera innehåll som korrekt trots uppenbara felaktigheter. Därför ligger det yttersta ansvaret för innehållets korrekthet hos oss författare.

AI har inte använts för att fatta självständiga beslut i frågor som kräver etiska överväganden, juridisk bedömning eller professionell expertis. I sådana fall fungerar AI enbart som ett kompletterande verktyg. Ingen känslig eller personligt identifierbar information har delats med AI-system utan att det finns ett tydligt stöd för detta och att relevanta regelverk följs.

Sammanfattningsvis har AI enbart använts som ett hjälpmedel och dess användning har ämnat att effektivisera arbetsprocesser och förbättra kvaliteten av både struktur och text. Användningen har skett i samförstånd och full medvetenhet om AIs tekniska och etiska begränsningar och vi har en tydlig ambition att säkerställa att slutresultatet håller hög faktamässig och etisk standard.

Konsekvenser av AI-genererade kodförslag

För att stödja programmeringsarbetet användes Claude Code (främst Opus-modellen) som verktyg för generering av kodförslag. Det förtjänar en reflektion som går utöver att bara konstatera att verktyget användes, eftersom det inte

enbart påverkade vad vi byggde utan också hur vi byggde det.

Arbetssättet med AI-genererade kodförslag skiljer sig från traditionell programmering. I stället för att skriva varje kodrad själva formulerade vi vad vi ville uppnå och fick förslag tillbaka, som vi sedan granskade, testade och justerade. Det förändrade arbetet från att skriva kod till att i högre grad utvärdera kod. Den största praktiska effekten var att tröskeln för att testa en idé sjönk kraftigt. När det går snabbt att få fram ett första utkast blir det enkelt att pröva flera lösningar, vilket gör att man experimenterar mer än vad man annars hade gjort.

Trots dessa fördelar finns det även nackdelar som kan påverka studiens genomförande och bör beaktas. När kod genereras snabbt finns en risk att man accepterar lösningar man inte fullt ut förstår, och att den intuition man normalt bygger upp genom att brottas med ett problem själv uteblir. Vi har försökt motverka detta genom att granska och testa all genererad kod, men det förändrar inte att förståelsen för delar av implementeringen delvis är medierad genom Claude Code.

3 Tidigare forskning

3.1 Mänskliga värderingsbrister och jämförelse med AI-baserade modeller

Tidigare forskning inom området visar att flera olika typer av maskininlärningsmetoder kan förbättra kvaliteten av fastighetsvärderingar även om det är oklart huruvida AI-baserade värderingsinstrument överpresterar mänskliga värderingar gentemot realiserade försäljningspriser. Till exempel visar tidigare forskning att de största bristerna inom människodrivna värderingar är inkonsekvens och variabilitet mellan olika värderingsmän. Variation framkommer bland olika värderingsmän i deras bedömning av både subjektiva och objektiva aspekter av fastigheter. Exempelvis visar studier att olika typer av värderare enbart är överens om en fastighets skick i 32,3 % av fallen och 26,2 % av fallen rörande designkvalitativa element som till exempel planlösning, estetik och funktion (Teikari m. fl. 2025, s. 3). Likaså uppkommer skillnader gentemot olika värderingsmän och deras bedömning av en fastighets boyta, där studier visar att en uppmätt boyta skiljer mer än $\pm 9 \text{ m}^2$ i 25 % av fallen mellan olika värderingsmän. På grund av boytans väsentliga betydelse i en fastighetsvärdering ger detta i monetära termer upphov till en prisskillnad på mellan 200 000 kr - 500 000 kr i slutpris beroende på marknadsförhållanden (Teikari m. fl. 2025, s. 3).

I förlängningen kan dessa och liknande diskrepanser leda till omfattande civilrättsliga tvister och skadeståndskrav från såväl köpare som säljare (Högsta domstolen mål nr T 2838-20). Forskning visar också att AI-baserad fastighetsvärdering har möjligheten att minska fenomenet *contract price confirmation bias*. Fenomenet betyder att en värderare i oproportionerligt hög grad anpassar sin värdering till ett överenskommet köppris i ett köpekontrakt (Alexandrov, Goodman och Neal 2023). Fannie Maes forskning har visat att när en värderare är medveten om den faktiska köpeskillingen värderade denne en fastighet över eller lika med köpeskillingen 23 % oftare än vad en värderare omedveten om köpeskillingen eller en AVM gjorde (Eriksen m. fl. 2020b, s. 4). Tillika var de 467 % mer benägna att justera sin värdering genom ojämn viktning när en värdering hamnade under en köpeskillning (Eriksen m. fl. 2020b, s. 3). Resultatet av Contract price confirmation bias i värderingssammanhang är att värderare medvetna om köpeskillingen värderar en fastighet 4,2 % till 8,3 % högre än omedvetna värderare och AVMer (Eriksen m. fl. 2020a).

Trots en mänsklig värderares tendenser att både övervärdera och dess bias så presterar faktiskt dessa bättre under stabila marknadsförhållanden (Birkeland m. fl. 2021, s. 4). En mänsklig värderares *Median Absolute Percentage Error* (MdAPE) var 3,0 % under en stabil marknad medan en AVMs modell var 5,4 % under samma period (Birkeland m. fl. 2021, tabell 5, s. 24). Under mer dynamiska marknader, i studien karaktäriseras detta av en marknad som först steg 24 % och sen föll 6 % under ett år, är dock både en AVM och en mänsklig värderares MdAPE "likvärdiga i exakthet" (Birkeland m. fl. 2021, s. 4). Samma studier visar dock på att en AVM kan ha stora skillnader i dess prediktiva prestanda

beroende på geografiskt läge, där Zillows AVMs MdAPE kunde skilja mellan 3,3 % och 8,2 % gentemot olika amerikanska städer (Birkeland m. fl. 2021, tabell 5, s. 24).

3.2 Integrationen av AI och mänsklig värdering i praktiken

Som ovan nämnda studier visar finns det aspekter där traditionell fastighetsvärdering överpresterar AI-baserad fastighetsvärdering och vice versa. Den ganska självklara lösningen är förstås hybridmodeller där vissa aspekter hanteras av mänskliga värderare och andra av AI-algoritmer för att hitta den optimala balansen mellan kostnad, effektivitet och noggrannhet (Teikari m. fl. 2025, s. 6). Det hybrida arbetssättet speglar marknadens förståelse att olika värderingssituationer kräver olika metoder. I dessa kan enklare värderingar helt baseras på externa bilder och allmänt tillgänglig information (exempelvis fastighetsregistret) medan mer komplexa objekt kräver avancerad utrustning. I dessa fall delar hybridmodellen på datainsamling och analys så att fälttekniker samlar standardiserat material som certifierade värderare analyserar på distans. Detta skapar möjligheter för specialiserade aktörer att fokusera på enstaka delar av processen istället för helhetslösningar (Teikari m. fl. 2025, s. 42).

Utvecklingen visar samtidigt som arbetssättet blir mer hybridorienterat förblir både icke-rutinmässiga och mer komplexa uppgifter fortfarande beroende av mänsklig expertis även om det förstärks i allt större utsträckning av AI-baserade verktyg. Resultatet av detta är att uppgifter som komplex analys, kundkontakt och professionella bedömningar blir allt viktigare för mänskliga värderare (Teikari m. fl. 2025, s. 28). En av de tekniska metoder som förekommer inom AI-baserad fastighetsvärdering är *Stacked Generalization*, eller *Stacking*. Detta betyder att man kombinerar flera AI-baserade modeller till en metamodel som väger deras resultat utifrån hur bra de presterar, vilket kan möjliggöra mer träffsäkra prediktioner än en enskild modell (Björgve m. fl. 2025, s. 641). Av alla enskilda modeller presterade XGBoost bäst, som hade en MdAPE på 5,24 % medan en stacked generalization-model hade ett MdAPE på 5,17 % vilket tyder på att stacked generalization enbart ger marginella förbättringar och i huvudsak förlitar sig på XGBoosts icke-linjära beräkningsförmåga. Likaså uppstår ökade beräkningskostnader vid stacked generalization vilket ytterligare tyder på att begränsningar vid praktiskt användningen av stacking (Björgve m. fl. 2025, s. 640). Den andra implementeringen av AI-modeller är som ovan nämnt hybridmodeller eller AI-förstärkt värdering. Dessa brukar i sin tur delas upp i två, *Compound AI Systems* och *Agentic AI*. I Compound AI systems fall kombineras flera specialiserade AI-system och modeller för att sköta olika delsystem som till exempel bildanalys, marknadsdata och rapportskrivning (Raghavan m. fl. 2025). Agentic AI system fokuserar å andra sidan på att självständigt söka i databaser och utföra preliminära analyser vilket sparar tid och effektiviserar en värderares arbetsflöde (Qin m. fl. 2023).

3.3 AI i fastighetsvärdering: rättvisa, transparens och finansiella risker


Införandet av AI i fastighetsvärdering medför betydande effektiviseringspotential, men aktualiserar samtidigt komplexa etiska, juridiska och samhällseliga utmaningar som kräver systematisk hantering. Dessa utmaningar präglar allt ifrån algoritmisk rättvisa, systemrisker och finansiell stabilitet, black box-problem, arbetsmarknadsproblem, samt väcker frågor om integritet och datainsamling. Problemen med algoritmisk rättvisa handlar framförallt om att en AI har tendenser att reproducera historisk problematisk data (Jonker och Rogers 2024). Det kan till exempel röra sig om historiska data präglade av strukturerad diskriminering och rasism, som i USA präglade mörkhyade och latinoamerikanska områden. Om en AI i sin tur tränas på denna historiska data lär den sig att fastigheter i dessa områden bör ha lägre värden, oavsett objektiva egenskaper (Teikari m. fl. 2025, s. 19). Även om dessa variabler, exempelvis ras eller religion, vanligtvis inte används i modellen, kan modellerna ofta skapa proxyvariabler som säger samma sak genom att extrapolera ut det från till exempel namn, postnummer och språkliga beskrivningar (Teikari m. fl. 2025, s. 19). Genom att försöka lösa diskrimineringsfrågan uppstår i sin tur problemet att man i princip måste använda positiv särbehandling genom att vikta dessa objekt olika från andra vilket kan leda till konflikter mellan rättvisepprinciper, där strävan efter gruppbaserad likvärdighet riskerar att skapa orättvisa behandlingar på individnivå (Teikari m. fl. 2025, s. 20).

Systemrisker och finansiell stabilitet är också aspekter som påverkas av AI-baserad fastighetsvärdering, inte enbart enskilda värderingar (Teikari m. fl. 2025, s. 16). Problemen som uppstår är inte olika de problem som uppstår vid algoritmbaserad handel på finansmarknaden både i karaktär och sett till exponerad kapitalmängd (Teikari m. fl. 2025, s. 23). Modellhomogenisering är det som framstår som mest problematiskt i sammanhanget. Modellhomogenisering innebär att flera olika marknadsaktörer använder sig av samma eller liknande modeller tränade på överlappande material. Konsekvensen av detta blir att det kan leda till synkroniserade under- och övervärderingar som hotar den globala finansiella stabiliteten, likt finanskraschen 2008 (Teikari m. fl. 2025, s. 24). Det andra problemet som alstras är algoritmiska återkopplingar. I takt med att AI-modeller sköter allt fler modeller kommer dessa värderingar i sin tur bli träningsdata för nya modeller. Detta kan skapa självuppfyllande *feedback*-loopar och prisbubblor som är frikopplade från ekonomiska fundament (Teikari m. fl. 2025, s. 23). Ansvarsskyldighet är en annan aspekt som påverkar AI-baserad fastighetsvärdering. Ogenomskinliga komplexa modeller är ett hinder mot rättssäkerheten. Det kan till exempel komma att uppstå frågor när traditionella mekanismer för yrkesansvar och skadeståndsskyldighet blir otydliga när en algoritm bidrar till eller i ensamhet har ett beslut (Teikari m. fl. 2025, s. 16). På arbetsmarknaden kan AI dessutom komma att förändra värderingsmannens yrkesroll och skapa en risk för social utmatning (Teikari m. fl. 2025, s. 28). Yrket riskerar att delas upp i högkvalificerade specialister och lågkvalificerade datainsamlare (Teikari m. fl. 2025, s. 30). Medan de mellanskikt av traditionella värderare, som utför störst

andel av rutinuppgifter, är de som utsätts för högst automatiseringstryck (Teikari m. fl. 2025, s. 30). Samtidigt kommer nya tekniker inom datainsamling som till exempel 3D-skanning och drönare att utgöra integritetsrisker. Till skillnad från traditionella foton skapar omfattande 3D-skanningar permanenta, detaljerade register över privata bostäder, personliga ägodelar och livsstilsmönster. Därav finns det behov av tekniska lösningar som automatiskt filtrerar bort personliga dokument, barnrum eller värdefulla föremål från den data som lagras (Teikari m. fl. 2025, s. 10).

4 Explainable AI (XAI)

För att motverka problemen med AIs black box har *explainable AI* (XAI) vuxit fram. Explainable AI försöker bryta upp black box-metodiken som många moderna AI-modeller använder sig av, se figur 2. Syftet med en explainable AI är att skapa metoder och tekniker som gör det möjligt för människor att både förstå och kunna kritiskt granska de beslut en AI tar (Arrieta m. fl. 2019).



Figur 2: Visar flödet av indata (ekonomiska faktorer, historiska transaktioner osv.) genom en ogenomskinlig algoritmisk modell (AI Black Box) till utdata, i detta fallet en fastighetsvärdering. Källa: Egen framställning.

Inom fastighetsvärdering hade en AI som använder sig av en opak black box som endast levererar ett diskret utfall enbart levererat en värdering på en prompt av en användare, utan möjligheten för användaren att kunna granska de kritiska beslut och avvägningar modellen gjorde för att beräkna resultatet. En explainable AI hade istället isolerat och kvantifierat de bakomliggande beslutsfaktorerna som ligger till grund för värderingen (Kee och Ho 2025a).

Inom ramen för XGBoost, som är en modell av en icke-linjär natur använder den funktioner som *Shapley Additive Explanations* (SHAP-värden) för att dekonstruera enskilda prediktorer och därmed kunna visa hur den predikterar ett resultat.


4.0.1 XGBoost

XGBoost är en maskinlärningsmetod som främst används för att skapa prediktiva modeller av hög noggrannhet. XGBoost är särskilt vanligt inom tillämpningar med strukturerad data, exempelvis fastighetsrelaterade data. Rent matematiskt byggs den prediktiva förmågan i XGBoost upp av en objektiv formel, se formel 1. Denna består av en förlustfunktion och en regulariseringsterm. Förlustfunktionen mäter avvikelser mellan ett observerat värde och modellens prediktion medan regulariseringstermen summeras över modellens samtliga beslutsträd och ämnar till att begränsa modellens komplexitet.

$$L(\Phi) = \sum_{i=1}^n l(\hat{y}_i, y_i) + \sum_{t=1}^T \Omega(f_k) \quad (1)$$

Formel 1: Objektiva funktionen i XGBoost bestående av förlustfunktion och regularisering

XGBoost bygger på *ensemble*-lärande. Ensemble-lärande innebär att flera enkla modeller kombineras till en gemensam modell. Vanligtvis utgörs de enskilda modellerna av beslutsträd. Varje enskilt beslutsträd har en relativt begränsad prediktiv förmåga men genom att träna modellen sekventiellt skapas nya beslutsträd som försöker förbättra de prediktioner som tidigare träd haft svårt att förklara (T. Chen och Guestrin 2016). Genom varje iteration adderas nya beslutsträden till modellen som i sin tur minskar den sammanlagda modellens förlustfunktion, se figur 3.



Figur 3: Schematisk illustration av XGBoost där modellen sekventiellt byggs upp av k antal beslutsträd $f_k(x, \theta_k)$. Varje träd tränas på residualer av tidigare träd och θ_k representerar ett träds struktur och parametrar. Källa: Egen framställning.

Ur ett värderingsperspektiv innebär detta i praktiken att modellen successivt förbättrar sina prediktioner. Inledningsvis fångas de mest dominerade sambanden av beslutsträden, till exempel belägenhet, boarea och tomtarea. Därefter används ytterligare beslutsträd för att förklara kvarstående avvikelser och minska förlustfunktioner. Detta möjliggör att mindre tydliga och mer komplexa samband beaktas i modellens prediktiva förmåga.

Anledningen till att XGBoost valdes är för att XGBoost erbjuder praktiska fördelar som andra maskinlärningsmetoder inte erbjuder. XGBoost kräver till exempel mindre bearbetning och förbehandling av data jämfört med neurala nätverk. Dessutom är XGBoost relativt snabbare och hanterar saknade värden bättre än andra maskinlärningsmetoder (Kee och Ho 2025a). Kombinerat betyder det att

XGBoost ansågs som den mest lämpade maskinlärningsmetoden sett till våra behov då fastighetsrelaterade data karaktäriseras av många observationer med många variabler. Likaså är prediktiv noggrannhet och praktiskt implementation varit av central betydelse varpå återigen XGBoost bedömdes vara bäst lämpat.

XGBoost är även relativt robust mot *outliers*. Detta beror på att modellen bygger på beslutsträd som delar upp datan i mindre segment, vilket gör att enskilda outliers inte får lika stor påverkan på helheten som i exempelvis linjära modeller. Istället påverkar de främst den specifika del av datan där de förekommer.

Vidare bidrar modellens inbyggda regularisering till att begränsa modellens komplexitet, vilket minskar risken att den anpassas för mycket till enskilda datapunkter eller brus i datan. Tillsammans gör detta att XGBoost kan ge stabila prediktioner även när datamängden innehåller vissa outliers. (He och Y. Chen 2025)

4.0.2 Målfunktionen

Inom XGBoost är målfunktionen ett centralt begrepp. Modellen XGBoost skapar optimeras genom att minimera objektivfunktionen. Målfunktionen innehåller ett mått på hur väl en modell predicerar ett värde gentemot det observerade värdet, förlustfunktionen, se formel 2. Alltså appliceras förlustfunktionen gentemot objekt där alla variabler redan är kända för att sedan kunna uppdateras för att minska förlustfunktionen. Förlustfunktionen kan modelleras på olika sätt beroende på problem däribland kvadratisk fel för regression. Målfunktionen består utöver en förlustfunktion även utav en regulariseringsterm, se formel 3. Regulariseringstermen straffar modellen för varje nytt beslutsträd som skapas, vilket hindrar modellen för att bli för komplex.

$$\sum_{i=1}^n l(\hat{y}_i, y_i) \Rightarrow \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (2)$$

Formel 2: Exempel på förlustfunktion, bestående av generell förlustfunktion och kvadratisk fel för regression

$$\Omega(f_k) = \gamma K + \frac{1}{2} \lambda \sum_{j=1}^K w_j^2 \quad (3)$$

Formel 3: Regulariseringsterm, straffar modellen desto fler beslutsträd som skapas

När sedan förlustfunktionen och regulariseringstermen appliceras på träningsdata styr de hur modellen i framtiden justerar beslutsträden och för att minska

prediktionsfelen och förhoppningsvis finna en balans mellan prediktiv förmåga samt förmågan att generalisera till ny data.

4.0.3 Överanpassning

Termen överanpassning innebär att modellen blir för komplex. Detta innebär att för många beslutsträd har skapats och i sin tur att modellen anpassas för mycket till träningsdata. Detta medför risken att modellens prediktioner blir fel då modellen plockar upp slumpmässigt brus i träningsdatan när den predicerar ett värde för ett okänt objekt. Ett tecken på att en modell håller på att överanpassas är när träningsfelet minskar medan testfelet ökar under träningen av modellen. En viktig egenskap med XGBoost är att det innehåller inbyggda system för regularisering (T. Chen och Guestrin 2016). Detta innebär modellens komplexitet kontrolleras under träning vilket hjälper till att motverka överanpassning.

4.0.4 Underanpassning

Underanpassning är motsatsen till överanpassning. Det uppstår främst när modellen är för enkel och därmed inte fångar upp genomgripande trender i testdatan. Inom XGBoost innebär detta till exempel att beslutsträden är för få eller för grunda. Ett resultat av underanpassning är att prediktiva prestandan i både test och träningsdata är systematiskt felaktiga. För att mitigera riskerna av underanpassning kan modellen justeras så att den skapar fler beslutsträd, djupare beslutsträd eller ökar inlärningshastigheten, *learning rate*. Det hjälper modellen att bättre fånga upp data men kan riskera överanpassning.

Utöver justering av modellens parametrar är en av de mest effektiva metoderna för att motverka underanpassning så kallad *feature engineering*. Detta innebär att man tillför nya variabler med hög prediktiv relevans till modellen. Exempel på sådana variabler är makroekonomiska faktorer som bolåneränta och KPI-index, samt lokala prisindikatorer, såsom medianpriset per kvadratmeter för de tio närmaste grannfastigheterna (T. Chen och Guestrin 2016).

4.0.5 SHAP-värden

SHAP-värden utgör en teoretisk välgrundad metod för att tolka prediktioner från komplexa maskinlärningsmetoder, där ibland XGBoost. Metoden baseras på Shapley-värden som i sin tur är en metod inom kooperativ spelteori. Inom kooperativ spelteori är Shapley en metod att fördela vinsten i ett kooperativt spel mellan spelare (Lundberg och Lee 2017). Varje spelares bidrag beaktas som en genomsnittlig marginaleffekt över alla möjliga ordningar i vilka spelarna kan ansluta till koalitionen. I SHAP-ramverkets anpassning till maskinlärning översätts spelare till förklaringsvariabler, spelets värde till modellens prediktion och koalitioner till delmängder av *features*. I en modell rörande fastighetsvärdering innebär detta att varje enskild prediktion kan dekonstrueras i additiva komponenter som visar hur olika egenskaper, till exempel boyta, värdeår eller geografiskt läge påverkar modellens slutgiltiga värdeestimat relativt ett basvärde.

SHAP är särskilt användbart i kombination med XGBoost då det är just implementationen av SHAP som gör modellen till en explainable AI och inte en black box-AI (Kee och Ho 2025a). SHAP låter inte enbart en användare analysera vilka variabler som är mest betydelsefulla globalt över hela modellen utan även hur en viss variabel påverkar enskilda observationer och huruvida variabeln är positiv, negativ eller icke-linjärt. SHAP bör dock användas och tolkas med viss försiktighet. SHAP beskriver hur modellen tolkar och använder informationen i datamängden den är tränad på, men SHAP-värdena etablerar inte i sig det kausala sambandet mellan fastighetsattribut och marknadsvärde. Därav är SHAP-värdena i sig beroende av kvaliteten av modellen och datamaterialet som bygger upp modellen. Trots ovan nämnda begränsningar erbjuder SHAP en transparent och analytiskt robust ansats för att stärka förståelsen och öka förmågan att granska en värdering gjord av XGBoost.

4.0.6 Fördjupning av black-box problematiken

Som nämdes i bakgrunden (avsnitt 1.1) är black box-problematiken olika akut för olika AI-metoder, och det är värt att precisera var XGBoost placerar sig. Problemet bör förstås som ett spektrum snarare än en egenskap en modell antingen har eller saknar. XGBoost är inte fri från black box-problematik. En tränad modell består av ett stort antal sekventiella beslutsträd vars sammanlagda logik i praktiken är omöjlig att överblicka manuellt, och modellen kan därför inte i sig redogöra för varför den gav ett visst utfall. Däremot skiljer den sig på flera avgörande sätt från de metoder där problemet är som mest påtagligt. XGBoost är en väletablerad metod som arbetar på strukturerad data med mänskligt tolkbara variabler som exempelvis boarea, byggår och läge. Det gör att enskilda prediktioner i efterhand kan analyseras på variabelnivå med hjälp av SHAP, vilket lindrar men inte helt eliminerar problemet. För djupa neurala nätverk och stora språkmodeller, såsom Claude, ChatGPT och Gemini, är situationen en annan. Dessa arbetar på ostrukturerad data genom ett mycket stort antal parametrar utan mänskligt tolkbar innebörd, vilket gör dem betydligt svårare att granska. Distinktionen är dock inte enbart akademisk för detta arbete. Claude har använts som stöd vid generering av kodförslag under utvecklingsprocessen (se avsnitt 2), vilket innebär att den metodklass där transparensproblemen är som störst har varit närvarande i arbetets genomförande. Däremot utgör språkmodellen inte en del av den slutliga värderingsmodellen eftersom den bygger på XGBoost.

5 Modellexperiment

Detta kapitel beskriver arbetets praktiska del, där en egen AI-baserad värderingsmodell för småhus utvecklas och utvärderas. Fokus ligger på datainsamling, databearbetning, geokodning, konstruktion av variabler samt modellträning och validering.

5.1 Valet av XGBoost som AI-modell

Det finns flera alternativa AI-modeller för prediktionsuppgifter, såsom Random Forest, neurala nätverk samt andra *gradient boosting*-metoder som LightGBM och CatBoost. I denna studie valdes dock XGBoost som huvudsaklig algoritm. Valet grundar sig dels i modellens dokumenterade lämplighet för strukturerad data med många variabler, vilket är typiskt för fastighetsrelaterade dataset (Kee och Ho 2025b, s. 2118), dels i tidigare forskning som visar att XGBoost ofta uppvisar hög prediktionsförmåga inom fastighetsvärdering (Kumkar m. fl. 2018). Genom detta val har studien tagit avstamp i etablerad vetenskaplig praxis, och därför säkerställs en robust metodologisk grund. En mer utförlig beskrivning av metodens egenskaper samt motiv till valet av XGBoost presenteras i avsnitt 4.0.1.

5.2 Datakälla

Som primär datakälla används Värderingsdata och deras ortspristjänst, en väletablerad svensk fastighetsdatatjänst som tillhandahåller uppgifter om samtliga småhusförsäljningar i Sverige. Tjänsten erbjuder detaljerad information för varje transaktion, däribland boarea (BOA), biarea (BIA), köpeskilling, taxeringsvärde, byggår, värdeår, standardpoäng samt geografiska indelningar som län, kommun och distrikt. Åtkomst till tjänsten har erhållits via lärosätet. En översikt över samtliga variabler från Värderingsdata som används i projektet presenteras i tabell 1. Tabellen omfattar de variabler som används i utvecklingen av AI-modellen, inte enbart de som ingår i den slutgiltiga modellen. De slutliga modellvariablerna presenteras senare i kapitel 6.

Tabell 1: Beskrivning av variabler från Värderingsdata

Variabel	Beskrivning
Adress	Fastighetens adress
Fastighetsbeteckning	Unik beteckning för fastigheten (exempelvis STUDENTEN 1:2)
Kontraktsdatum	Datum då köpekontraktet undertecknades
Slutpris (kr)	Faktiskt transaktionspris vid försäljning
BOA (m ²)	Boarea, det vill säga boyta i kvadratmeter
Byggår	Ursprungsår då byggnaden uppfördes
Värdeår	År som används vid taxering för att spegla byggnadens värde
Ombyggnadsår	År för större om- eller tillbyggnad
Tomtareal (m ²)	Fastighetens tomtstorlek i kvadratmeter
K/T	Kvot mellan slutpris och taxeringsvärde
Pris/kvm (kr/m ²)	Pris per kvadratmeter baserat på slutpris
Bebyggelsestyp	Typ av byggnad, exempelvis friliggande, radhus eller kedjehus
Tax. BIA (m ²)	Biarea enligt taxeringsuppgifter
Värdearea (m ²)	Sammanvägd area baserad på BOA och BIA som används vid taxering
Taxeringsår	År då taxeringsvärdet fastställdes
Antal byggnader	Antal byggnader på fastigheten
Standardpoäng	Poäng som anger byggnadens standardnivå (externt & internt)
Typkod	Kod som klassificerar fastighetstyp enligt Skatteverket
Överlåtelseform	Form av överlåtelse, exempelvis äganderätt eller tomträtt
Tomträtt	Anger om fastigheten upplåts med tomträtt
Nyproduktion	Indikerar om byggnaden är nyproducerad
Vatten	Typ av vattenförsörjning
Avlopp	Typ av avloppslösning
Energiklass	Byggnadens energiklass
Kwh/m ² /år	Energianvändning per kvadratmeter och år
Belägenhet (strand)	Indikerar närhet till strand eller vatten
Publiceringsdatum	Datum då objektet publicerades till försäljning
Annonstid (dagar)	Antal dagar objektet varit ute till försäljning
Utgångspris (kr)	Initialt begärt pris vid annonsering
Budpremie (kr)	Skillnad mellan slutpris och utgångspris i kronor
Budpremie (%)	Skillnad mellan slutpris och utgångspris i procent
Län	Län där fastigheten är belägen
Kommun	Kommun där fastigheten är belägen
Distrikt	Mindre geografisk indelning än kommunen

5.3 Målvariabel och träningsprincip

I en prediktiv modell definieras en målvariabel, det vill säga den storhet som modellen ska förutsäga. I detta projekt är målvariabeln *Slutpris (kr)*, vilket motsvarar den faktiska köpeskillingen vid en fastighetstransaktion. Slutpriset, även kallad köpeskillingen, speglar det pris som marknaden faktiskt varit villig att betala vid försäljningstillfället och utgör därför en naturlig approximation av marknadsvärdet.

Alternativa mått, såsom utgångspris eller taxeringsvärde, används inte som målvariabel. Utgångspriset sätts av säljare eller mäklare och kan variera strategiskt, vilket innebär att det inte nödvändigtvis representerar fastighetens marknads-

värde. Taxeringsvärdet är å andra sidan en administrativ uppskattning som ofta baseras på schabloner och historiska underlag, och är därför inte tillräckligt precist för att användas som målvariabel i en datadriven värderingsmodell.

Modellen tränas på historiska transaktionsdata där varje observation består av målvariabeln (Slutpris) samt ett antal beskrivande variabler, så kallade features, exempelvis boarea, bygghår och geografiskt läge. Genom träningen identifierar modellen statistiska samband mellan dessa variabler och målvariabeln. Principen liknar den i klassisk linjär regression, där variationer i målvariabeln förklaras av variationer i de ingående variablerna.

Vid användning av modellen för att värdera en fastighet matas dess features in, varefter modellen predikterar ett förväntat slutpris givet fastighetens samtliga egenskaper och läge.

5.4 Inledande prototyparbete

Projektets inledande fas syftade till att undersöka om automatiserad fastighetsvärdering med maskininlärning var genomförbar givet de resurser och den tid som stod till förfogande. En första prototypmodell byggdes med hjälp av XGBoost-algoritmen i Python, baserad på fiktiva och slumpmässigt genererade data. Syftet med denna prototyp var inte att producera meningsfulla resultat, utan att etablera en grundläggande förståelse för den tekniska infrastrukturen, inklusive programmeringsspråket Python, relevanta bibliotek såsom xgboost, scikit-learn, pandas och numpy, samt arbetsflödet för träning och utvärdering av XGBoost-modell. Resultatet bekräftade att ansatsen var teoretiskt genomförbar och gav en grund att bygga vidare på.

5.5 Första modelliteration - regional prototyp

Med tillgång till Värderingsdata.se laddades initialt cirka 10 000 småhusförsäljningar i Skåne län ned. Baserat på detta dataset utvecklades en mer avancerad modell jämfört med den inledande prototypen. Arbetet under denna fas fokuserade på att bygga ett stabilt och återanvändbart ramverk. Detta innefattade utveckling av ett grafiskt användargränssnitt för interaktion med modellen, en systematisk undersökning av XGBoost-algorithmens hyperparametrar samt identifiering av vilka oberoende variabler som bör inkluderas som features i modellen.

Den viktigaste insikten från denna fas var behovet av att kvantifiera fastighetens läge på ett mer precist sätt. Inom fastighetsvärdering är läget en av de mest avgörande värdepåverkande faktorerna. Den geografiska information som Värderingsdata.se tillhandahöll i form av län, kommun och distrikt utgjorde en god utgångspunkt. Sveriges distriktsindelning, som infördes den 1 januari 2016, består av 2 523 områden och utgår från den territoriella församlingsindelning som gällde den 31 december 1999. (Statistikmyndigheten SCB 2024) Distrikten visade sig vara särskilt användbara för att fånga lägesvärde på mikronivå, i synnerhet i landsbygdsområden och homogena bostadsområden där försäljningar inom ett givet distrikt uppvisade likartade prisnivåer.

Problemet uppstod dock i storstäder och större tätorter, där prisvariationen kunde vara avsevärd även inom ett och samma distrikt. Ett illustrativt exempel är distriktet Limhamn i Malmö, där genomsnittliga försäljningspriser inom ena delen av distriktet uppgick till cirka 35 000 kronor per kvadratmeter, medan fastigheter vid några gator emellan betingade priser kring 63 000 kronor per kvadratmeter. Distriktsindelningen var med andra ord för grovmaskig för att fånga denna typ av prisgradient.

5.6 Geokodning av fastighetsdata

För att erhålla större precision i lägesbestämningen genomfördes geokodning av samtliga fastighetsförsäljningar. Till detta användes Nominatim API, en öppen geokodningstjänst kopplad till OpenStreetMap (OSM). Genom att skicka in adress, fastighetsbeteckning och kommun kunde API:et returnera latitud- och longitudkoordinater för respektive försäljningsobjekt.

Geokodningen fungerade i huvudsak väl, men vissa felkällor identifierades. Vid analys av avvikelserna framkom att de vanligaste felen orsakades av gatunamn tillhörande mindre, lantliga vägar som inte kunde lokaliseras korrekt av Nominatim. API:et matchade i dessa fall gatunamnet mot en gata med samma namn i en annan, vanligtvis större, kommun. För att hantera denna problematik implementerades en verifieringsrutin som kontrollerade att de returnerade koordinaterna geografiskt befann sig inom rätt kommun och distrikt, baserat på officiella administrativa gränser.

Inkluderingen av koordinater som oberoende variabler resulterade i omedelbart förbättrade modellprestanda, mätt i form av högre förklaringsgrad (R^2), lägre medianabsolut procentuellt fel (MdAPE) och stämde klarare överens med verkliga försäljningspriser.

5.7 Beslut om nationell modell och dataurval

Baserat på de lovande resultaten från den regionala prototypen togs beslutet att utvidga modellen till en automatiserad värderingsmodell för småhusförsäljningar i hela Sverige. Tidsperioden för dataurvalet sattes från 2018-01-01 till 2026-04-09, baserat på kontraktsdatum.

Valet av tidsperiod motiverades av flera faktorer. En längre tidshorisont innebär en större datamängd, vilket är väsentligt för modellens generaliserbarhet. Fastighetsdata präglas av hög dimensionalitet och komplexa samvariansmönster, vilket kräver tillräckligt djupgående beslutsträd för att XGBoost effektivt ska kunna identifiera relevanta samband. Vidare innebär den valda perioden att modellen exponerades för flera skilda marknadsförhållanden och makroekonomiska chocker.

Perioden omfattar både uppgång och nedgång på bostadsmarknaden. Efter bostadspriskorrigeringen 2017 följde en återhämtning under 2018-2019, medan bostadspriserna steg kraftigt under 2020-2021 i samband med covid-19-pandemin

och låga räntenivåer. Under 2022 skedde en tydlig marknadsnedgång i samband med hög inflation och snabba räntehöjningar, delvis kopplade till energikrisen och den ekonomiska osäkerhet som följde av Rysslands fullskaliga invasion av Ukraina. Under de efterföljande åren har räntenivåerna gradvis stabiliserats och bostadsmarknaden visat tecken på återhämtning. (Finansinspektionen 2024)

5.8 Datainsamling

Värderingsdata:s webbgränssnitt medförde praktiska begränsningar för storskalig datainsamling. Tjänsten tillät maximalt 10 000 försäljningar per urval och nedladdning kunde enbart ske sidvis med högst 200 rader per sida. Detta innebär att manuell nedladdning av hela datamängden var praktiskt genomförbar, men otroligt krävande.

I den första datainsamlingsomgången tillämpades relativt snäva filterkriterier i syfte att maximera datakvaliteten. Ett Python-skript utvecklades för att automatisera nedladdningsprocessen. Skriptet simulerade användarbeteende i webbgränssnittet och utförde sekventiella sidnedladdningar automatiskt. Eftersom urvalet var begränsat till 10 000 poster i taget behövde nya urval bekräftas manuellt, varefter skriptet återtog den automatiska nedladdningen. Processen pågick under cirka en till två dagars arbete och resulterade i ungefär 350 000 fastighetsförsäljningar.

Vid analys av den insamlade datamängden framkom dock att de snäva filterkriterierna hade resulterat i att cirka 40 procent av alla småhusförsäljningar under den aktuella tidsperioden exkluderats. Detta bedömdes som en betydande brist, då modellen behöver exponeras för hela marknadens bredd för att kunna göra tillförlitliga värderingar. En andra datainsamlingsomgång genomfördes därför med väsentligt bredare filterkriterier. Den enda begränsningen som tillämpades var att transaktionerna skulle avse småhusförsäljningar inom den definierade tidsperioden och att gåvor, arvsöverlåtelse och liknande icke-marknadsmässiga transaktioner exkluderades. Detta visade sig dock inte vara helt fallet och beskrivs senare i avsnitt 5.16.

Den totala datainsamlingen resulterade i cirka 600 000 småhusförsäljningar, fördelade över ungefär 3 000 separata Excel-filer med 200 poster vardera.

5.9 Databearbetning och kvalitetssäkring

Innan datasetet användes för modellträning genomfördes en systematisk bearbetnings- och kvalitetssäkringsprocess. Processen syftade till att förbättra datakvaliteten samt säkerställa spårbarhet genom att borttagna observationer sparades separat i varje steg.

5.9.1 Sammanslagning, borttagning av dubletter och sammanfattningsrader

Sammanslagning av filer

Samtliga Excel-filer sammanfogades till en enda CSV-fil med hjälp av Python-biblioteket `pandas`. Denna fil utgjorde den huvudsakliga grunden för modellens träningsprocess och fungerade som utgångspunkt databearbetningen och kvalitetssäkringen. CSV-formatet valdes för dess effektivitet vid inläsning och bearbetning av stora datamängder. I jämförelse kan Excel-filer i dessa storlekar ta upp till fem gånger längre tid att läsa in och bearbeta än CSV-filer.

Borttagning av dubletter

Eftersom nedladdningen skedde i överlappande urval om 10 000 poster, gav det upphov till exakta dubletterader. Dessa identifierades genom jämförelse av samtliga kolumnvärden. Om två rader var identiska i alla avseenden behölls den första förekomsten och övriga togs bort.

Borttagning av sammanfattningsrader

Varje Excel-fil från Värderingsdata innehöll en automatiskt genererad sammanfattningsrad med rubriken "Medelvärden", som representerade medelvärden för alla numeriska kolumner. Dessa rader identifierades och togs bort med hjälp av tre kriterier: (1) indexkolumnen innehöll texten "Medelvärden", (2) avsaknad av adressuppgift, samt (3) fastighetsbeteckning angiven som "-".

5.9.2 Hantering av semikolonseparerade cellvärden

I vissa celler förekom semikolonseparerade värden när en fastighet omfattade flera byggnader med olika egenskaper, exempelvis "Byggår" med värdet "1991;1995", vilket indikerar att byggnaderna uppfördes 1991 respektive 1995. För att hantera detta gjordes aritmetisk aggregering, borttagning och val av första värde. Se text och tabell 2 nedan.

Numeriska kolumner - aritmetisk aggregering

Semikolon-värdena för Byggår, Värdeår, Ombyggnadsår och Standardpoäng ersattes med medelvärdet av de ingående värdena. Andelen berörda rader var låg: Byggår 0,27 %, Värdeår 1,13 %, Ombyggnadsår 0,11 % och Standardpoäng 1,38 %.

Kategoriska kolumner - borttagning

För kolumnerna Bebyggelsestyp och Typkod togs rader med semikolonseparerade värden bort helt, då det saknades entydigt sätt att reducera multipla kategorier till en enda. Detta påverkade enbart cirka 170 rader (0,028 % av datasetet).

Beskrivande kategorier - första värde

För kolumnerna Vatten, Avlopp och Belägenhet behölls det första värdet före semikolonet, under antagandet att det representerar huvudegenskapen. Andelen berörda rader var 0,18 % för Vatten, 0,18 % för Avlopp och 0,02 % för Belägenhet.

Tabell 2: Andel berörda rader per kolumn och tillämpad strategi

Kolumn	Berörda rader av datasetet	Strategi
Byggår	0,27 %	Medelvärde
Värdeår	1,13 %	Medelvärde
Ombyggnadsår	0,11 %	Medelvärde
Standardpoäng	1,38 %	Medelvärde
Bebyggelsestyp	0,023 %	Rad borttagen
Typkod	0,005 %	Rad borttagen
Vatten	0,18 %	Behåll första
Avlopp	0,18 %	Behåll första
Belägenhet	0,02 %	Behåll första

5.9.3 Borttagning av grova outliers

För att förbättra datakvaliteten genomfördes ett filtreringssteg där observationer med tydligt orimliga värden togs bort. Fasta gränsvärden användes för fem centrala variabler som bedömdes vara avgörande för att identifiera och avlägsna outliers. Detta gjordes för att enkelt kunna avgöra vad som är rimliga värden för småhus på den svenska marknaden.

Följande gränsvärden användes:

Tabell 3: Tillämpade gränsvärden för filtrering av outliers

Variabel	Nedre gräns	Övre gräns
Slutpris (kr)	50 000	50 000 000
BOA (m ²)	20	1 000
Byggår	1700	2026
Tomtareal (m ²)	0	100 000
Antal byggnader	1	7

Gränsvärdena baserades på vad som anses rimligt på fastighetsmarknaden. Till exempel bedöms försäljningar under 50,000 kr inte vara marknadsmässiga, utan snarare felregistreringar, särskilda överlåtelse eller andra fastighetstyper som

inte utgör småhus. På samma sätt anses småhus med boyta under 20 m² inte vara representativa. Det kan också noteras att inga fastigheter i datasetet hade ett slutpris över 50 000 000 kr.

Totalt identifierades och togs cirka 3 382 observationer bort (0,56 %). Fördelningen per variabel visas nedan:

Tabell 4: Antal borttagna observationer per variabel

Variabel	Borttagna
Slutpris (kr) för lågt (< 50 000 kr)	1 424
BOA för liten (< 20 m ²)	1 201
Antal byggnader för högt (> 7)	467
Byggår för tidigt (< 1700)	173
Tomtareal för stor (> 100 000 m ²)	161
Summa	3 382

Även om XGBoost är relativt robust mot outliers (avsnitt 4.0.1), valdes dessa observationer bort. Genom att endast inkludera rimliga och marknadsmässiga försäljningar minskar mängden brus i datan. Det gör det lättare för modellen att hitta relevanta samband, vilket i sin tur kan förbättra modellens prestanda.

5.10 Geokodning av det nationella datasetet

5.10.1 Behovet av koordinater

I likhet med den regionala prototypen (avsnitt 5.5) behövdes koordinater i form av latitud och longitud för drygt 600 000 fastighetsförsäljningar i det nationella datasetet. Koordinaterna utgör en förutsättning för att konstruera de lägeskänsliga ingångsparametrarna till AI-modellen.

5.10.2 Skalningsutmaning och alternativanalys

Den tidigare geokodningen av 10 000 fastigheter i Skåne hade tagit ungefär 3 timmar att genomföra. En uppskalning till 600 000 poster innebar en förväntad körtid på cirka 360 timmar, det vill säga omkring 15 dygn. Den huvudsakliga begränsande faktorn var Nominatim API:ets hastighetsbegränsning, som tillåter högst ett anrop per sekund i enlighet med deras användningsvillkor. Varje enskild fastighet krävde således minst en sekunds bearbetningstid enbart för API-kommunikationen.

Som alternativ till Nominatim utvärderades Googles Geocoding API, baserat på Google Maps. Denna tjänst erbjuder högre genomströmning och hade kortat ner processen till cirka 2 dygn. Men det är en betaltjänst, och en kostnadsuppskattning visade att geokodning av hela datamängden skulle uppgå till cirka 3 000 amerikanska dollar, vilket bedömdes som oproportionerligt högt i förhållande till tiden som skulle vunnits. Därtill är en av examensarbetets vägledande principer att undersöka vad som är möjligt att åstadkomma med begränsade resurser

och fritt tillgängliga verktyg. Beslutet blev därför att behålla Nominatim som geokodningstjänst och acceptera den längre bearbetningstiden.

5.10.3 Anpassning av geokodningsskriptet för långvarig drift

Det geokodningsskript som använts för den regionala prototypen var dimensionerat för enstaka körsessioner om några timmar. En körning om 15 dygn, motsvarande cirka 360 timmar, ställde väsentligt högre krav på robusthet och feltolerans. Skriptet genomgick därför ett antal modifieringar.

För att minimera antalet API-anrop, och därmed spara tid, skapades ett cache-system. Eftersom vissa fastigheter har sålts flera gånger i det aktuella datasetet, kunde geokodningsresultatet från det första anropet lagras och återanvändas vid efterföljande försäljningar av samma objekt. Cachen nyckeln baserades på den kombinationen av fastighetsbeteckning och kommun som är unik för varje fastighet. Eftersom en fastighets geografiska koordinater är konstanta behandlas en fastighet med ny beteckning korrekt som en ny post. Denna optimering minskade både körtider, belastningen på den externa tjänsten (Nominatim) och risken att potentiellt överskrida dess anropskvoter.

Geokodningsskriptet sparade löpande resultaten efter varje tusende rad, vilket innebar att endast ett mycket begränsat antal observationer riskerade att gå förlorade vid ett oväntat stopp.

En återupptagningsmekanism implementerades även, vilket gjorde det möjligt för skriptet att vid omstart identifiera den senast bearbetade raden och fortsätta geokodningen därifrån. Detta innebar att den pågående processen inte behövde initieras om från början vid förekomst av ett avbrott.

För att minska behovet av manuell övervakning infördes också ett system för automatisk felnotifiering. Vid oväntade programkrascher eller kritiska fel skickades en e-postavisering, vilket gjorde det möjligt att snabbt identifiera och åtgärda problemet.

Slutligen implementerades mer robust felhantering för nätverksproblem, timeout och tillfälliga API-avbrott. Detta säkerställde att enskilda misslyckade anrop inte avbröt hela processen utan istället kunde försöka igen vid ett senare tillfälle.

Med dessa anpassningar genomfördes geokodningen framgångsrikt under en sammanhängande period om drygt 14 dygn. Det resulterande datasetet, där koordinater kopplats till samtliga rader i datasetet.

5.10.4 Validering av koordinater

Den verifieringsrutin som utvecklades för den regionala prototypen (avsnitt 5.6) låg till grund för valideringsprocessen, men behövde väsentligt utökas för att hantera det nationella datasetets skala och komplexitet.

När den kompletta koordinatdatan väl hade säkerställts och det tidigare för-

skjutningsfelet åtgärdats, återstod att kontrollera att koordinaterna faktiskt var korrekta. En inledande manuell granskning av ett urval fastighetsförsäljningar hade avslöjat ett systematiskt problem: geokodnings-API:et hade i ett antal fall returnerat koordinater som placerade fastigheten på fel geografisk plats. Att tilldela en maskinlärningsmodell felaktiga positionsdata är i princip värre än att inte tillhandahålla positionsdata alls, eftersom modellen då tränas på ett konsekvent och dolt fel utan möjlighet att identifiera avvikelser. Det ansågs därför nödvändigt att genomföra en systematisk valideringsprocess.

Valideringen genomfördes i två steg och byggde på geografiska gränsfiler (GeoPackage-format) från Lantmäteriets Geodataportalen: varsin fil med Sveriges officiella distriktsindelning och kommungränser.

Steg 1: Distriktvalidering

För varje observation med tillgängliga koordinater kontrollerades huruvida koordinatpunkten geografiskt låg inom det distrikt som angavs i datamängden. En mindre bufferzon om 30 meter tillämpades kring distriktsgränserna för att absorbera mindre geokodningsfel och inexaktheter i adressuppslaget. Syftet var att undvika att observationer felaktigt klassificeras som ogiltiga när koordinaten hamnat precis utanför en administrativ gräns. Eftersom geokodning aldrig är helt exakt bedömdes det som rimligt att acceptera mindre avvikelser nära gränsen. Det visade sig dock att distriktskolumnen innehöll ett bindestreck ("–") eller saknade värde i 9 % av fallen istället för ett giltigt distriktsnamn, vilket innebar att en del observationer inte kunde valideras mot distriktslagret.

Steg 2: Kommunvalidering

För observationer utan giltig distriktbeteckning, men med koordinater, genomfördes i stället en validering mot kommungränserna. Kommunkolumnen var genomgående ifylld i datasetet, vilket möjliggjorde en fullständigt "fall-back" för dessa rader. En bufferzon om 100 meter tillämpades runt kommungränserna för att hantera fastigheter belägna nära en kommungräns. Även här var motivet att undvika att mindre positionella avvikelser skulle leda till felaktig exkludering av observationer.

Resultat

Totalt processades cirka 600 000 fastighetsförsäljningar. Av dessa saknade ungefär 4,5 % koordinatvärden helt, medan resterande cirka 95,5 % kunde tilldelas koordinater via geokodning. Av dessa bedömdes omkring 91 % av det totala antalet observationer som geografiskt giltiga efter valideringen, antingen via distrikts- eller kommungränser. Cirka 4,5 % av koordinaterna placerade fastigheten utanför förväntad geografisk enhet. Åtgärden var inte att exkludera dessa observationer, utan att ersätta de felaktiga koordinaterna med blanka värden. Motiveringen är att även om positionsdata är felaktig, kvarstår övrig information som relevant för modellen, såsom boarea, byggår och slutpris. XGBoost kan dessutom effektivt hantera saknade värden (Kee och Ho 2025b, s. 2116), vilket gör att

observationerna fortfarande kan bidra till modellens träning.

Det bör understrykas att det även bland de validerade observationerna kan förekomma enstaka felaktiga koordinater som råkat hamna inom rätt distrikt eller kommun trots att den ursprungliga geokodningen var inkorrekt. Därutöver utvecklades kompletterande metoder för att identifiera och exkludera icke-marknadsmässiga transaktioner och statistiska avvikare, vilket beskrivs i avsnitt 5.16. Sammantaget bedömdes den geokodade och validerade koordinatinformationen hålla tillräcklig kvalitet för att tjäna som geografisk precisionsindikator i modellen.

5.11 Kategorisk kodning

XGBoost, liksom de flesta maskininlärningsalgoritmer, kan enbart bearbeta numeriska värden. Datasetet innehöll dock ett flertal kategoriska variabler i textform, exempelvis kommun "Växjö", distrikt "Limhamn" eller vattenförsörjning "Kommunalt vatten". Dessa variabler omvandlades till numeriska representationer med hjälp av *label-encoding*, en form av kategorisk kodning där varje unikt textvärde inom en kolumn tilldelas ett heltal. Saknade eller tomma värden kodades som NaN (Not-a-number), vilket möjliggör för XGBoost att automatiskt hantera dessa som saknade värden genom dess inbyggda mekanismer. Faktiska kategorier tilldelades löpande heltal med start från 1. För varje kolumn skapades en ny kolumn med suffixet `_code` som placerades direkt efter originalkolumnen i datasetet.

Tabell 5 sammanfattar samtliga kolumner som label-encodades samt den kodningsmetod som tillämpades.

Tabell 5: Kategoriska variabler och tillämpad kodningsmetod

Variabel	Kodningsmetod	Beskrivning
Kommun	Nominell	Label-encoding
Län	Nominell	Label-encoding
Distrikt	Nominell	Label-encoding
Typkod	Nominell	Label-encoding
Bebyggelseyp	Nominell	Label-encoding
Belägenhet	Nominell	Label-encoding
Vatten	Nominell	Label-encoding
Avlopp	Nominell	Label-encoding
Energiklass	Ordinal	Heltalskodning i stigande ordning (A = 1, B = 2, ..., G = 7) som bevarar rangordningen.
Tomträtt	Binär	1 om tomträtt, 0 i övriga fall.
Nyproduktion	Binär	1 om nyproduktion, 0 i övriga fall.

Nativt kategoriskt stöd i XGBoost

Utöver label-encoding aktiverades XGBoosts inbyggda stöd för kategoriska variabler (`enable_categorical=True`) för samtliga nominella variabler, det vill säga Kommun, Län, Distrikt, Typkod, Bebyggelsestyp, Belägenhet, Vatten, Avlopp, Nyproduktion och Tomträtt. De label-encodeade kolumnerna konverterades till datatypen `pd.Categorical` i Pandas, varpå XGBoost med trädmetoden `hist` automatiskt utför optimala partitioneringar (subset-splits) vid varje nod. Detta innebär att algoritmen vid en kategorisk split kan gruppera godtyckliga delmängder av kategorier till vänster respektive höger barn, till skillnad från standardbeteendet med numeriska variabler där enbart en uppdelning baserad på ett tröskelvärde är möjlig.

Denna metod passar särskilt bra för nominella variabler med många olika värden, såsom Kommun (290 unika värden) och Distrikt (över 2 500 unika värden), där den numeriska ordningen av label-encoding-värdena annars saknar meningsfull tolkning. Med nativa kategoriska splits undviks problemet att modellen tolkar godtyckligt tilldelade heltal som en ordnad skala.

Notera att för binära variabler som Nyproduktion och Tomträtt (med enbart två möjliga värden, 0 eller 1) ger den kategoriska behandlingen inget annorlunda beteende jämfört med en numerisk split. Det finns bara ett möjligt uppdelningsställe oavsett metod. Den kategoriska behandlingen är därmed primärt relevant för variabler med fler än två nivåer.

Samtliga mappningar mellan textvärden och tilldelade heltal exporterades till en JSON-fil. Detta säkerställer att kodningen är reproducerbar och att mappningarna kan återanvändas vid framtida prediktioner på ny data.

5.12 Tidsrelaterade variabler

Kolumnen *Kontraktsdatum* innehöll datum i textformat. För att möjliggöra modellering av tidsdimensionen skapades tre nya variabler: *Kontrakt_År*, *Kontrakt_Månad* samt *Kontrakt_Tidsindex*.

Tabell 6: Härledda tidsvariabler

Variabel	Beskrivning	Exempel
Kontrakt_År	År för kontrakt	2022
Kontrakt_Månad	Månad (1–12)	6
Kontrakt_Tidsindex	Månader sedan jan 2018	54

Tidsindexet beräknades som antal månader sedan januari 2018, vilket utgör startpunkt för datasetet. Variabeln ger en kontinuerlig tidsrepresentation och underlättar för modellen att identifiera trender över tid. Samtliga variabler placerades direkt efter originalkolumnen.

5.13 Avstånd till centralort

För att komplettera den geografiska informationen skapades variabeln *Distans_till_centrum_km*, som mäter avståndet till närmaste centralort.

Avståndet beräknades med haversine-formeln, som ger det kortaste avståndet mellan två punkter på jordytan baserat på latitud och longitud (Sinnott 1984). För varje fastighetsförsäljning beräknades avståndet till samtliga centralorter i Sverige, och det minsta avståndet valdes. Se formel 4 nedan.

$$d = 2r \arcsin \left(\sqrt{\sin^2 \left(\frac{\varphi_2 - \varphi_1}{2} \right) + \cos(\varphi_1) \cos(\varphi_2) \sin^2 \left(\frac{\lambda_2 - \lambda_1}{2} \right)} \right), \quad (4)$$

där:

- d = avståndet mellan punkterna längs jordytan (km).
- r = jordens medelradie, 6 371 km.
- φ_1, φ_2 = latitud för punkt 1 respektive punkt 2 (radianer).
- λ_1, λ_2 = longitud för punkt 1 respektive punkt 2 (radianer).

Syftet med variabeln är att fånga hur centralt eller perifert en fastighet är belägen. I områden med få transaktioner kan variabeln fungera som en proxy för tillgång till service och arbetsmarknad, vilket ofta påverkar prisnivån negativt ju längre bort man befinner sig. I mer urbana områden förväntas effekten vara mindre.

Variabeln inkluderades ändå, eftersom XGBoost kan hantera variabler med låg betydelse genom att ge dem mindre vikt i modellen. Dess faktiska påverkan analyseras vidare med hjälp av SHAP-värden i modellutvärderingen.

5.14 Makroekonomiska variabler

För att kunna koppla varje enskild försäljning till det ekonomiska läget vid tidpunkten för transaktionen skapades en makrodatafil med fyra variabler på månadsnivå. Även om modellen i teorin kan lära sig sådana samband själv, kan det vara fördelaktigt att direkt inkludera variabler som speglar konjunkturen. Det gör det enklare för modellen att fånga hur marknadsläget påverkar prisnivåer, utan att behöva härleda dessa samband enbart från fastighetsdata. Inom maskininlärning är det välkänt att relevanta variabler ofta förbättrar både modellens inlärning och dess förmåga att generalisera.

De fyra variablerna är:

- **Styrränta**

Riksbankens reporänta, hämtad från Riksbanken. Räntan lagras per månad baserat på beslutsdatum och gäller fram till nästa förändring.

- **KPI (Konsumentprisindex)**

Hämtas från SCB:s API via tabellen KPI2020M (tabell-ID PR0101A) inom ämnesområdet Priser och konsumtion (PR/PR0101). Indexet har basår 2020 = 100 och visar den allmänna prisutvecklingen i Sverige per månad. Två serier används: skuggindex (ContentsCode: 00000807) för historiska värden och fastställda tal (ContentsCode: 00000808) för nyare perioder, där fastställda tal prioriteras vid överlapp.

- **Bolåneränta**

Hämtas från SCB:s API via tabellen RantaT04N (tabell-ID FM5001C) inom ämnesområdet Finansmarknad (FM/FM5001). Variabeln avser den genomsnittliga bolåneräntan till hushåll och inkluderar samtliga monetära finansinstitut, utestående avtal och alla räntebindningstider. Den hämtade variabeln (ContentsCode: 000004ZW) anges i procentenheter.

- **Arbetslöshet**

Hämtas från SCB:s API via tabellen AKURLBefM (tabell-ID AM0401A) inom ämnesområdet Arbetsmarknad (AM/AM0401). Variabeln avser säsongsrensad arbetslöshet i procent (Arbetskraftstillh: ALÖSP, TypData: SR_DATA) för befolkningen 15–74 år (Ålder: tot15-74), båda könen (Kön: 1+2). Serien baseras på Arbetskraftsundersökningen (AKU).

5.15 Lokala prisankare

En av de centrala utmaningarna vid fastighetsvärdering med AI är att fånga den lokala prisnivån, alltså att likvärdiga hus kan ha mycket olika marknadspriser beroende på läge. Modellen har visserligen tillgång till koordinater (latitud och longitud) samt geografiska koder som kommun och distrikt, men dessa variabler innehåller inte någon direkt information om prisnivån i området. Ett distriktskodnummer säger till exempel inte att västra delen av Limhamn (ett distrikt i västra Malmö) är dyrare än den östra delen. Prisskillnaderna kan vara betydande, särskilt i stadsmiljöer och i synnerhet i storstäder. Även om modellen fångar mycket genom koordinaterna ger ett tydligt prisankare i rätt riktning en extra vägledning och hjälper modellen att snabbare hamna på en rimlig prisnivå.

Fyra kompletterande features konstruerades för att ge modellen ett lokalt prisankare: *Area_Median_m2*, *KNN_Price_m2*, samt tidigare försäljningsvariablerna *Prev_Sale_Price* *Prev_Sale_Months_Ago*.

5.15.1 Tidsjustering med SCB:s prisindex

Alla fyra prisankare bygger på historiska försäljningar, vilket skapar ett grundläggande problem: bostadspriserna förändras över tid. En median beräknad på försäljningar från 2018 till 2026 blandar prisnivåer från helt olika marknadslägen. För att lösa detta normaliseras samtliga priser till en gemensam referensperiod

med hjälp av SCB:s officiella småhusprisindex.

Prisindexet hämtades från SCB:s API (tabellen SmahusT2M, Småhusbarometern) och innehåller ett tremånaders rullande medelprisindex per län och månad. Indexvärdena laddades till en lokal uppslagstabell med nyckeln (länskod, år, månad).

Vid tidsjustering beräknas varje observations normaliserade pris per kvadratmeter enligt formel 5 nedan:

$$\text{pris per m}^2_{\text{justerat}} = \frac{\text{Slutpris}}{\text{BOA}} \times \frac{\text{Prisindex}_{\text{ref}}}{\text{Prisindex}_{\text{försäljningsmånad}}} \quad (5)$$

där $\text{Prisindex}_{\text{ref}}$ är indexvärdet vid en fast referensperiod (senaste tillgängliga perioden i datasetet) och $\text{Prisindex}_{\text{försäljningsmånad}}$ är indexvärdet vid det län och den månad då fastigheten såldes.

Observationer utan matchande indexvärde faller tillbaka på ojusterat pris per kvadratmeter. Denna tidsjustering säkerställer att samtliga lokala prisankare uttrycks i samma prisnivå, oavsett när de underliggande transaktionerna faktiskt ägde rum.

5.15.2 Area_Median_m2, distriktets medianpris

Variabeln *Area_Median_m2* representerar det tidsjusterade medianpriset per kvadratmeter i det distrikt där fastigheten är belägen. Beräkningen bygger enbart på träningsdata för att undvika dataläckage.

Implementationen använder en hierarkisk fallback-strategi:

- Distriktsnivå: om distriktet har minst 10 observationer i träningsdatan används distriktsmedianens tidsjusterade pris per kvadratmeter.
- Kommunnivå: om distriktet har för få observationer faller variabeln tillbaka på kommunens tidsjusterade median.
- Global median: i de sällsynta fall där varken distrikt eller kommun har tillräcklig data används en global median över hela träningsdatan.

Denna kaskad ger modellen en stabil referensprisnivå för samtliga observationer, utan att introducera brus från distrikt med få datapunkter.

5.15.3 KNN_Price_m2, grannskapsbaserat prisankare

Medan *Area_Median_m2* ger en aggregerad prisnivå per distrikt, fångar *KNN_Price_m2* den ännu mer lokala prisvariationen genom att identifiera de tio geografiskt närmaste försäljningarna baserat på latitud, longitud och haversi-neavstånd. För varje observation beräknas en viktad median av dessa grannars

tidsjusterade priser per kvadratmeter.

Flera skyddsmekanismer implementerades:

- Temporal filtrering: vid träning av modellen tillåts enbart grannar vars kontraktsdatum ligger före eller vid samma tidpunkt som den aktuella observationen. Detta förhindrar att framtida försäljningar läcker in i beräkningen så kallat *data-läckage*.
- Deduplicering: varje fysisk fastighet tillåts bidra med högst en observation. Om en fastighet har sålts flera gånger väljs den tidsmässigt närmaste försäljningen.
- Självexkludering: den aktuella fastigheten exkluderas ur sin egen grannmängd, identifierad via kommunkod och fastighetsbeteckning.

Priserna är, liksom *Area_Median_m2*, tidsjusterade med SCB:s prisindex till den gemensamma referensperioden, vilket innebär att grannarnas priser uttrycks i samma penningvärde oavsett om försäljningen skedde år 2018 eller 2026.

5.15.4 *Prev_Sale_Price* och *Prev_Sale_Months_Ago*, försäljningsvariablerna

Variabeln *Prev_Sale_Price* anger det senaste kända försäljningspriset för samma fastighet, och *Prev_Sale_Months_Ago* anger hur många månader som förflutit sedan den försäljningen.

En tabell som använts för att hitta tidigare försäljningar vid en värdering byggs och sorteras kronologiskt per fastighet. Vid uppslag för en given observation används binärsökning för att hitta den senaste försäljningen *Prev_Sale_Price*. Observationer utan tidigare försäljning får tomt värde, vilket XGBoost hanterar utan problem.

Till skillnad från de två övriga prisankarna tidsjusteras *Prev_Sale_Price* inte, utan anges i det nominella priset vid den tidpunkten. Anledningen är att modellen har tillgång till *Prev_Sale_Months_Ago* samt makrovariabler och tidsindex, och därmed själv kan lära sig relationen mellan ett historiskt pris och förväntad prisförändring.

5.15.5 Varför normalisering behövs trots tidsvariabler

En rimlig fråga är varför tidsjustering av prisankarna överhuvudtaget behövs, givet att modellen redan har tillgång till tidsvariabeln *Kontrakt_Tidsindex* (antal månader sedan datasettets startpunkt).

Svaret ligger i hur gradient boosted trees arbetar. XGBoost bygger besluts-träd med binära jämförelser av typen “är $KNN_Price_m2 \leq 45\,000$?”. Om KNN-värdet speglar det nominella priset vid grannens försäljningstidpunkt, utan tidsjustering, skulle ett värde på 35 000 kr/m² kunna innebära antingen ett

billigt område (2024) eller ett normalprissatt område (2016). Modellen skulle behöva lära sig komplexa interaktioner mellan *KNN_Price_m2* och tidsvariabler för att kompensera för denna förväxling. I praktiken innebär det ett mycket svårare optimeringsproblem.

Genom att normalisera prisankarna till en gemensam referensperiod elimineras denna tidsdimension ur variablerna, och de uttrycker enbart det som modellen behöver: var är det dyrt respektive billigt. Tidsdimensionen hanteras separat av tidsindex och makrovariabler (styrränta, bolåneränta, KPI). Denna separation gör varje variabel mer informativ i isolation och förenklar det mönster modellen behöver lära sig.

5.16 Hantering av icke-marknadsmässiga försäljningar

Trots den filtrering som genomfördes vid datainsamlingen (avsnitt 5.8) visade det sig att ett betydande antal icke-marknadsmässiga transaktioner kvarstod i datasetet. Upptäckten gjordes efter att de lokala prisankarna (avsnitt 5.15) hade implementerats, genom att användargränssnittet för varje objekt visade de tio närmaste grannförsäljningarna. Vid en rutinmässig testvärdering av modellen uppmärksammades att en granne sålts för cirka 1 000 000 kronor, medan övriga i området låg kring 5 000 000–6 000 000 kronor. En stickprovsanalys bekräftade att liknande avvikelser förekom på flera platser i datan.

Varför dessa transaktioner fanns kvar i datan

Den exakta orsaken till att dessa observationer förekommer är inte helt klarlagd. Däremot finns det ett antal rimliga förklaringar:

- **Närståendeöverlåtelse.** Försäljningar inom familjen sker ofta till priser under marknadsvärdet. Dessa registreras vanligtvis som vanliga köp och passerar därmed standardfilter.
- **Dolda andelsöverlåtelse.** En person som redan äger en andel av fastigheten (till exempel 50 % efter arv eller separation) köper resterande andel. Om transaktionen registreras som ett köp av hela fastigheten, exempelvis på grund av saknad eller felaktig information om andel, framstår köpeskillingen som onormalt låg.
- **Avstyckning.** Fastigheten kan ha förändrats mellan två försäljningar. Ett vanligt scenario är att en stor tomt styckas av i flera delar som säljs separat. När den kvarvarande fastigheten senare säljs är det en betydligt mindre tillgång, vilket ger en lägre köpeskillning trots att fastighetsbeteckningen kan vara densamma i datat.
- **Tekniska fel i köpeskillingen.** Det kan förekomma registreringsfel i underliggande data, exempelvis från inskrivningsmyndigheten. Detta rör sig sannolikt om en mindre andel observationer, men kan bidra till extrema avvikelser som inte fångas av automatiska kontroller.

Gemensamt för dessa fall är att köpeskillingen inte speglar ett marknadsvärde, samtidigt som de är svåra att identifiera enbart utifrån tillgängliga variabler i rådata.

5.16.1 Filtrering baserat på K/T-kvot

För att hantera problemet implementerades ett filter baserat på K/T-kvoten, definierad som köpeskillig (Slutpris) dividerat med taxeringsvärde. Kvoten är ett etablerat mått inom fastighetsanalys. Ett K/T-värde långt under 1,0 indikerar att köpeskillingen understiger taxeringsvärdet, vilket är ovanligt vid normala småhusförsäljningar. Ett K/T värde över 5,0 innebär att köpeskillingen är fem gånger större än taxeringsvärde, vilket är ett extremt värde.

Givet informationen ovan implementerades följande trösklar:

Tabell 7: Tröskelvärden för filtrering baserat på K/T-kvoten

Filter	Tröskel
K/T undre gräns	0,7
K/T övre gräns	5,0

Tabell 8: Resultat av K/T-baserad filtrering

Filter	Borttagna observationer	Andel av dataset
K/T [0,7-5,0]	25 735	4,3 %

Att cirka 4,3 % av observationerna filtrerades bort, trots tidigare datarensning, indikerar att standardfiltren i Värderingsdatas gränssnitt inte fångar alla icke-marknadsmässiga transaktioner.

5.16.2 Justering av KNN-beräkningen

I samband med identifieringen av dessa avvikelser ändrades beräkningen av variabeln *KNN_Price_m2* från medelvärde till viktad median. Medelvärdet är känsligt för extremvärden, där en enstaka avvikande grannförsäljning kan påverka resultatet oproportionerligt mycket. Medianen är däremot mer robust och lämpar sig bättre för småhusdata, där prisdistributionen ofta är positivt skev. Den viktade varianten innebär dessutom att geografiskt närmare försäljningar ges större tyngd i beräkningen.

5.17 Logaritmisk transformering av målvariabeln

Bostadspriser är sällan jämnt fördelade. De flesta bostäder säljs inom ett mellanprisintervall, medan ett mindre antal dyrare objekt ligger långt över resten. Detta gör att fördelningen blir ojämn, med många observationer i mitten och några få mycket höga värden.

Att träna en modell direkt på råa slutpriser innebär att dessa höga värden får stort inflytande. Det leder ofta till att modellen underskattar billigare bostäder och överskattar dyrare.

En lösning är att transformera målvariabeln genom att använda logaritmen av slutpriset. Transformerings minskar de stora prisskillnaderna i den övre delen av fördelningen, vilket ger en mer symmetrisk och balanserad fördelning.

En viktig effekt är att modellen i praktiken lär sig relativa skillnader i pris snarare än absoluta. Det innebär att en viss procentuell avvikelse behandlas likvärdigt oavsett om det gäller en billig eller dyr bostad, vilket kan ge mer stabila prediktioner.

5.18 Modellträning och validering

5.18.1 Hyperparametrar

Slutmodellen tränas med hyperparametrar enligt tabell 9.

Förklaring av hyperparametrarna ges i tabell 10.

Tabell 9: Hyperparametrar för CV-modell och slutmodell

Parameter	CV-modell	Slutmodell
n_estimators	3 000	10 000
learning_rate	0,05	0,02
max_depth	9	11
min_child_weight	1	2
subsample	0,8	0,8
colsample_bytree	0,8	0,8
gamma	0,1	0,1
reg_alpha	0,1	0,1
reg_lambda	1,0	1,0
early_stopping_rounds	50	150

Tabell 10: Förklaring av hyperparametrar i XGBoost

Parameter	Förklaring
n_estimators	Antal beslutsträd i modellen. Fler träd kan förbättra anpassningen men ökar risken för överanpassning.
learning_rate	Stegstorlek vid uppdatering. Lägre värde ger stabilare men långsammare inlärning.
max_depth	Maximalt djup på träden. Djupare träd kan fånga komplexa samband men riskerar överanpassning.
min_child_weight	Minsta viktsumma i en nod för att tillåta vidare split. Högre värde ger mer generalisering.
subsample	Andel av träningsdata som används per träd. Minskar överanpassning.
colsample_bytree	Andel av variabler som används per träd. Minskar korrelation mellan träd.
gamma	Minsta förbättring i förlust som krävs för att dela en nod.
reg_alpha	L1-regularisering som uppmuntrar sparsamma modeller.
reg_lambda	L2-regularisering som begränsar modellens komplexitet.
early_stopping_rounds	Stoppa träningen om ingen förbättring sker efter ett antal iterationer.

5.18.2 Temporal walk-forward korsvalidering

Innan slutmodellen tränas används temporal korsvalidering för att kontrollera att modellupplägget fungerar stabilt över tid. Detta är ett diagnostiskt steg, inte en del av själva träningen, och syftar till att fånga eventuella problem som dataläckage eller instabil feature-konstruktion innan den slutliga modellen låses fast. Om resultaten är liknande mellan olika delar tyder det på stabil modellprestanda.

All data sorteras efter `Kontrakt_Tidsindex`. Därefter används `TimeSeriesSplit` med tre delar:

- Del 1: träning på den äldsta fjärdedelen, validering på nästa del
- Del 2: träning på hälften av datan, validering på nästa del
- Del 3: träning på tre fjärdedelar, validering på den sista delen

De läckagekänsliga variablerna `Area_Median_m2`, `KNN_Price_m2` och `Prev_Sale_Price` beräknas separat inom varje del, enbart baserat på träningsdelen. Valideringsdelen tilldelas därefter dessa värden utan att bidra till beräkningarna.

5.18.3 Slutmodell

Efter att modellen validerats tränas den slutliga modellen. Datan delas kronologiskt i en träningsdel och en testdel:

- 80 procent äldsta observationer används för träning
- 20 procent nyaste observationer används som testdata

Denna modell är den som sparas och används i praktiken.

5.18.4 Från slumpmässig split till temporal validering

Tidigare användes en slumpmässig uppdelning med `train_test_split` för både slutmodellen och korsvalideringen. Detta innebär att framtida observationer kunde ingå i träningsdata relativt testdata.

Eftersom variabler som `KNN_Price_m2` och `Area_Median_m2` baseras på träningsdata kunde dessa indirekt innehålla framtida information, alltså dataläckage. Detta ledde till överskattad modellprestanda.

Genom att införa temporal uppdelning säkerställs att endast historisk information används vid varje prediktion.

5.18.5 Hantering av `Prev_Sale_Price`

Variabeln `Prev_Sale_Price` representerar senaste tidigare försäljning för samma fastighet.

Trots att variabeln är stark finns det även här risk för dataläckage om framtida försäljningar inkluderas. Detta hanteras genom att endast tillåta matchning mot tidigare transaktioner.

Variabeln kompletteras med `Prev_Sale_Months_Ago`, vilket gör att modellen kan ta hänsyn till hur gammal informationen är.

5.19 SHAP - förklarbarhet och transparens

Som beskrivs i kapitel 4 möjliggör SHAP en uppdelning av modellens prediktioner i additiva bidrag per variabel. I detta projekt implementerades SHAP i två nivåer: lokal förklaring per enskild värdering och global feature-importans över hela modellen. Utöver SHAP analyserna implementerades även en kollinearitetsanalys som underlag för att reducera antalet variabler, samt en transparensrapport som vid varje värdering sammanställer all tillgänglig information om prediktionens tillförlitlighet.

5.19.1 Lokal SHAP

Vid varje värdering beräknas SHAP-värden för den specifika prediktionen. Eftersom modellen tränas på logaritmisk transformerat slutpris (se avsnitt 5.17)

uttrycks de råa SHAP-värdena i log-skala. För att göra resultatet begripligt konverteras varje bidrag till svenska kronor.

Resultatet presenteras som en sorterad lista där varje variabel visas med sitt inputvärde, SHAP bidrag i log-skala och motsvarande belopp i kronor. En typisk utskrift kan exempelvis visa att BOA bidrar med +850 000 kr medan byggår sänker med -120 000 kr. Användaren kan därmed direkt se vilka egenskaper som driver priset uppåt respektive nedåt för det aktuella objektet.

5.19.2 Global SHAP

Den globala SHAP analysen beräknar genomsnittlig absolut SHAP påverkan per variabel, baserat på ett slumpmässigt urval om 5 000 observationer ur träningsdatan. För varje observation konverteras bidraget till kronor, och därefter beräknas medelvärdet av absolutbeloppen över alla observationer.

Resultatet ger en ranking av variablernas generella betydelse för modellen. Denna ranking användes i praktiken som beslutsunderlag vid variabelreduceringen som beskrivs i avsnitt 5.19.3.

5.19.3 Kollinearitetsanalys och variabelreducering

Utöver SHAP implementerades ett verktyg för kollinearitetsanalys med syfte att identifiera variabler som i stor utsträckning förmedlar samma information. Analysen bygger på följande mått, där $|r| = 1$ innebär perfekt samband och 0 inget samband:

- Parvisa korrelationer: samtliga features med $|r| > 0.7$ flaggas, och par med $|r| > 0.9$ markeras med en extra varning.

XGBoost klarar kollinearitet utan problem för prediktion, då modellen väljer den variabel som ger bäst split i varje nod. Däremot blir SHAP-värdena mindre stabila vid hög kollinearitet, eftersom bidraget fördelas mellan korrelerade variabler. Om syftet är att tolka modellens beslut, inte enbart använda den för prediktion, finns det därmed skäl att reducera kollineära variabler.

Baserat på en kombinerad analys av global SHAP och kollinearitetsresultat reducerades modellen med fyra variabler, vilket sammanfattas i tabell 11.

Tabell 11: Borttagna features och motivering vid kollinearitetsbaserad reducering

Features	Motivering
Län	Redundant med latitude och longitude samt Kommun_code. Läns-koden är en grövre geografisk indelning som inte tillför ytterligare information.
Distrikt	Redundant med latitude, longitude och Area_Median_m2. Variabeln fångar främst lokal prisnivå som redan hanteras av prisankare.
Styrränta	Kollinär med Bolåneränta med korrelation nära 1. Bolåneränta behövs.
Kwh/m2/år	Ersattes av Energiklass. Variabeln hade hög andel saknade värden och den grövre klassificeringen bedömdes tillräcklig.

Som framgår av tabell 11 resulterade reduceringen i en modell benämnd ”cut-down”, med tre färre nettovariabler. Denna förändring försämrade inte modellens prediktionsprestanda men förbättrade tolkbarheten, då kvarvarande variabler i större utsträckning representerar oberoende informationsdimensioner.

5.19.4 Transparensrapport

I samband med varje lokal SHAP analys genereras en transparensrapport som sammanställer all tillgänglig kontextinformation kring prediktionen. Syftet är att ge användaren ett komplett underlag för att bedöma hur tillförlitlig värderingen är. Rapportens innehåll sammanfattas i tabell 12.

Tabell 12: Innehåll i transparensrapport

Sektion	Beskrivning
Datakvalitet	Andel variabler med definierat värde redovisas. Saknade variabler listas och vid fyllnadsgrad under 70 % ges en varning.
Konfidensintervall	Ett 90 procentigt intervall baserat på residualfördelningen i testdata, inklusive spridning relativt prediktionen.
Feature percentiler	Inputvärden jämförs med träningsdata. Extremvärden under 5:e eller över 95:e percentilen flaggas, medan 5 till 10 och 90 till 95 markeras som ovanliga.
Jämförbara försäljningar	Tio närmaste grannar visas med avstånd, tidsjusterat pris per kvadratmeter, boarea, kontraktsdatum och fastighetsbeteckning. Ett naivt estimat beräknas och jämförs med modellens prediktion.
Områdesstatistik	Antal observationer i distrikt och kommun redovisas. Vid få observationer flaggas ökad osäkerhet och eventuell fallback till kommunnivå.

Som visas i tabell 12 genereras transparensrapporten automatiskt utan extra input från användaren. Tillsammans med SHAP uppdelningen ger rapporten en samlad bild av vad modellen baserar sin värdering på, hur tillförlitligt resultatet är, samt vilka begränsningar som föreligger i det enskilda fallet.

5.20 Användargränssnitt

Ett grafiskt användargränssnitt utvecklades i Python med *tkinter* och *Streamlit*. Kärnfunktionen är prediktiv fastighetsvärdering via *Prognos*-knappen, kring vilken övriga funktioner är uppbyggda. Designen bygger på tre principer: minimera manuell inmatning via autocomplete och auto-ifyllning, ge transparens genom SHAP-analys och jämförbara försäljningar, samt möjliggöra iterativ utforskning. Tabell 13 listar de centrala funktionerna.

Tabell 13: Huvudfunktioner i gränssnittet.

Knapp	Syfte
Träna modell	Tränar XGBoost med korsvalidering.
Prognos	Värderar en fastighet prediktivt genom att guida användaren steg för steg.
Tweaka	Ändra enskilda variabler, köra om prognos.
Byt datum	Omvärderar samma fastighet vid annat datum.
SHAP (sista)	Förklarar prognosen: bidrag, osäkerhet, jämförbara försäljningar.
SHAP (global)	Vilka variabler bidrar mest generellt.

5.20.1 Prognosflödet

Knappen ”Prognos” vägleder användaren genom fyra steg, utformade för att minimera manuellt arbete.

Steg 1 och 2: Datum och beteckning

Användaren väljer först värderingsdatum. Därefter så kan användaren söka upp fastigheten på beteckning eller adress om den finns i datasetet, vilket möjliggör uppslag av tidigare försäljningar och fastighetsuppgifter.

Om fastigheten som ska värderas inte finns med i datasetet så får användaren fylla i alla ingångsvariabler manuellt.

Steg 3: Kartbaserat läge

En interaktiv karta öppnas i webbläsaren där användaren klickar för att ange plats. Programmet identifierar automatiskt latitud, longitud, kommun, distrikt och avstånd till centralort via rumslig analys mot officiella gränser.

Dessa uppgifter kan justeras manuellt vid behov i kartmiljön och programmet.

Steg 4: Ifyllning av egenskaper

Om beteckningen känns igen hämtas registrerade fastighetsuppgifter (boarea, tomtstorlek, byggår, energiklass, etc.) och presenteras för användaren, som ges möjlighet att verifiera och vid behov korrigera uppgifterna. Om ingen fastighet hittas kan användaren istället ange uppgifterna manuellt.

Steg 5: Presentation av det prediktiva värdet

I det sista steget så presenteras fastighetens ingångsvariabler och prediktiva värde i svenska kronor (SEK) enligt modellen.

5.20.2 Tweaka och byt datum: iterativ utforskning

Två funktioner stödjer snabb experimentering utan att börja om. *Tweaka* låter användaren ändra enskilda variabler och köra om prognosen, medan övriga värden behålls. *Byt datum* byter enbart värderingsdatum och räknar om alla datumberoende variabler (makrodata, KNN-pris, tidigare försäljningar). Det möjliggör frågor som “*Vad sker om boarean var 20 kvadratmeter större?*” eller “*Vad hade modellen värderat fastigheten i juni 2021?*”

5.20.3 SHAP-analys: slå på transparensen

Knappen *SHAP (sista)* genererar en rapport för senast gjorda värdering med varje variabls SHAP-bidrag, ett konfidensintervall baserat på modellens testfel, percentilanalys av invärdena, de tio närmaste KNN-försäljningarna samt områdesstatistik. Målet är att användaren ska kunna bedöma om värderingen är rimlig, om datakvaliteten är tillräcklig och om jämförelserna är vettiga.

SHAP (global) visar vilka variabler som bidrar mest till modellens prediktioner på hela datasetet.

5.20.4 Kompletterande datainsamling

Den ursprungliga datainsamlingen omfattade småhusförsäljningar med kontraktsdatum mellan 2018-01-01 och 2026-02-01, vilket resulterade i cirka 600 000 observationer. Eftersom projektet pågick under en längre period tillkom nya försäljningar löpande. Vid tidpunkten för modellens färdigställande och utvärdering bedömdes det därför som relevant att inkludera de två senaste månadernas data för att bättre spegla den aktuella marknadssituationen. Under denna period inträffade även betydande förändringar, såsom utbrottet av krig mellan USA och Iran den 28 februari 2026 samt en sänkning av kontantinsatsen från 15 % till 10 % (1 april). En kompletterande datainsamling genomfördes därför i början av april 2026, med syfte att inkludera försäljningar registrerade fram till 2026-04-09.

Den kompletterande datainsamlingen resulterade i cirka 10 000 ytterligare småhusförsäljningar. Dessa observationer genomgick samma bearbetnings- och kvalitetssäkringsprocess som det ursprungliga datasetet, såsom borttagning av outliers, hantering av semikolonseparerade cellvärden samt borttagning av dubletter.

De nya observationerna genomgick därefter samtliga steg för att skapa de variabler som används i modellen, såsom geokodning, kategorisk kodning, beräkning av tidsvariabler samt avstånd till närmaste centralort, etc.

Slutligen sammanfogades de nya observationerna med det befintliga datasetet, vilket resulterade i en total datamängd om cirka 610 000 småhusförsäljningar.

5.20.5 Lyxmodell och mjuk övergång

Under testning av modellen visade det sig att den hade svårare att förutsäga priser på de dyraste småhusen, särskilt i storstadsområden som Stockholm och Göteborg. Där verkar marknadens beteende skilja sig från övriga landet, speciellt i eftertraktade områden. För att hantera detta utvecklades en separat lyxmodell, tränad enbart på försäljningar i högsegmentet, definierat som tidsjusterade priser från 8 miljoner kronor och uppåt. Varför gränsen sattes vid 8 miljoner kronor är att detta motsvarar den 95:e percentilen i datan, det vill säga den nivå där de dyraste 5 procenten av försäljningarna börjar. Dessa gränsvärden är uppräknade med SCB:s prisindex, i linje med den metod som tidigare använts för prisankarna *KNN* och *Area_median_m2*.

Lyxmodellen optimerades med egna hyperparametrar för att bättre fånga prisvariationer och marknadseffekter i detta segment. Tabell 14 visar en jämförelse mellan grundmodellens och lyxmodellens konfiguration. De viktigaste skillnaderna är högre regularisering i lyxmodellen (ökad *reg_alpha* och *reg_lambda*) för att motverka överanpassning på mindre datamängd, högre *min_child_weight* för att kräva mer data per bladnod, och lägre *gamma* för mjukare trädsplittering.

Tabell 14: Hyperparametrar för grundmodell och lyxmodell (XGBoost).

Parameter	Grundmodell	Lyxmodell
<i>Träningsarkitektur</i>		
n_estimators	10,000	10,000
learning_rate	0.02	0.02
early_stopping_rounds	150	200
<i>Trädkomplexitet</i>		
max_depth	11	11
min_child_weight	2	5
gamma	0.1	0.05
<i>Regularisering</i>		
reg_alpha (L1)	0.1	0.5
reg_lambda (L2)	1.0	2.0
<i>Stokastiska tekniker</i>		
subsample	0.8	0.8
colsample_bytree	0.8	0.8

Vid prediktion används en tvåstegsprocess med en mjuk övergång. Grundmodellen predikterar först priset. Om priset ligger under 8 miljoner kronor används endast grundmodellen. Överstiger priset denna gräns aktiveras en gradvis övergång mellan modellerna.

Denna mjuka övergång innebär att:

- Vid 8 miljoner kronor används enbart grundmodellen.
- För varje miljon kronor över 8 miljoner ökar lyxmodellens andel linjärt med cirka 14 %.
- Vid 15 miljoner kronor används enbart lyxmodellen.

Denna design undviker plötsliga prissprång vid tröskelgränsen och ger en smidig anpassning för högvärdiga objekt. Resultatet är en modell som behåller stabiliteten i medelsegmentet och samtidigt blir mer träffsäker för de dyraste fastigheterna i marknadens toppskikt.

6 Resultat

I detta kapitel presenteras den slutliga modellens uppbyggnad och prestanda. Kapitlet inleds med en sammanställning av modellens variabler och hyperparametrar. Därefter redovisas modellens statistiska nyckeltal på testdata. Slutligen följer en jämförelse mellan modellens värderingar och referensmodeller samt faktiska försäljningspriser.

6.1 Modellens variabler

Den slutliga modellen, döpt till Movton, använder 26 beskrivande variabler, så kallade features, för att prediktera slutpris. Tabell 15 sammanfattar samtliga variabler, deras typ och en kort beskrivning.

Tabell 15: Samtliga 26 variabler i den slutliga modellen

Variabel	Typ	Beskrivning
<i>Läge</i>		
latitude	Numerisk	Latitud (WGS 84), se avsnitt 5.10
longitude	Numerisk	Longitud (WGS 84), se avsnitt 5.10
Kommun_code	Kategorisk	Numerisk kod för kommun, se avsnitt 5.11
<i>Fastighetsegenskaper</i>		
BOA (m ²)	Numerisk	Boarea i kvadratmeter
Värdearea (m ²)	Numerisk	Taxerad värdearea
Tax. BIA (m ²)	Numerisk	Taxerad biarea
Byggår	Numerisk	Byggnadens uppförandeår
Värdeår	Numerisk	Taxeringens värdeår
Tomtareal (m ²)	Numerisk	Tomtens areal
Typkod	Kategorisk	Fastighetstaxeringens typkod
Standardpoäng	Numerisk	Taxeringens standardpoäng
<i>Fastighetsflaggor</i>		
Energiklass_code	Kategorisk	Kodad energiklass (A-G)
Bebyggelseyp_code	Kategorisk	Friliggande, kedjehus, radhus m.m.
Belägenhet_code	Kategorisk	Typ av belägenhet
Vatten_code	Kategorisk	Typ av vattenanslutning
Avlopp_code	Kategorisk	Typ av avloppsanslutning
Nyproduktion_code	Kategorisk	Nyproducerad bostad eller ej
Tomträtt_code	Kategorisk	Tomträttsinnehav eller ej
<i>Lokala prisankare (se avsnitt 5.15)</i>		
Area_Median_m2	Numerisk	Tidsjusterat medianpris per m ² i distrikt
KNN_Price_m2	Numerisk	Medelpris per m ² från 10 närmaste grannar
<i>Tidsrelaterade och makroekonomiska (se avsnitt 5.12, 5.14)</i>		
Kontrakt_Tidsindex	Numerisk	Antal månader sedan januari 2018
KPI	Numerisk	Konsumentprisindex vid kontraktsdatum
Bolåneränta	Numerisk	Genomsnittlig bolåneränta vid kontraktsdatum
Arbetslöshet	Numerisk	Arbetslöshet vid kontraktsdatum
<i>Tidigare försäljning (se avsnitt 5.15)</i>		
Prev_Sale_Price	Numerisk	Senast kända försäljningspris för fastigheten
Prev_Sale_Months_Ago	Numerisk	Månader sedan föregående försäljning

Variablerna som rör fastighetsegenskaper och fastighetsflaggor härstammar direkt från datakällan Värderingsdata (se tabell 1), medan övriga variabler har konstruerats under projektets gång enligt metodbeskrivningen i kapitel 5. Vid kollinearitetsanalysen (avsnitt 5.19.3) reducerades fyra variabler bort, vilket sammanfattas i tabell 11.

6.2 Hyperparametrar

Modellens beteende styrs av ett antal hyperparametrar, vilka beskrivs i avsnitt 5.18.1. Tabell 9 visar de valda värdena för både CV-modellen och slutmodellen, och tabell 10 förklarar respektive parameter. Slutmodellen använder en lägre `learning_rate` (0,02 mot 0,05) och fler beslutsträd (`n_estimators` 10 000 mot 3 000) jämfört med CV-modellen, för att tillåta en mer gradvis inlärning på det större datasetet.

6.3 Modellprestanda

Den slutliga XGBoost-modellen tränades på cirka 465 000 observationer och utvärderades på cirka 116 000 observationer genom en temporal uppdelning, där träningsdata utgörs av äldre försäljningar och testdata av nyare. Modellen använder 26 variabler och tränades med log-transformerad målvariabel (`log1p` av slutpris). Träningen stoppades automatiskt vid 1 647 boosting-rundor av maximalt 10 000 till följd av early stopping. Tabell 16 sammanfattar slutmodellens prestanda på testdata.

Tabell 16: Slutmodellens prestanda på testdata

Mått	Värde
MedAE	352 762 kr
MdAPE	13,0 %
R^2	0,8710
Andel inom ± 10 %	39,3 %
Andel inom ± 15 %	54,3 %

Modellens R^2 -värde på 0,8710 innebär att cirka 87 procent av variationen i försäljningspris förklaras av modellen. MdAPE på 13 procent innebär att hälften av alla prediktioner avviker med mindre än 13 procent från det faktiska priset.

6.4 Korsvalidering

Innan slutmodellen tränades genomfördes en temporal walk-forward-korsvalidering med tre delar för att kontrollera att modellens prestanda är stabil över tid. Tabell 17 visar resultaten per del.

Resultaten visar att modellens prestanda förbättras successivt med mer träningsdata, vilket tyder på att modellen är stabil och inte överanpassad. Fold 3, som har mest träningsdata, uppvisar de bästa resultaten och ligger närmast slutmodellens prestanda. Att slutmodellen (MdAPE 13 %) presterar bättre än

Tabell 17: Resultat per fold, temporal walk-forward korsvalidering

Fold	Träning	Test	MedAE (kr)	R^2	MdAPE	$\pm 10\%$
1	145 353	145 351	445 829	0,8326	18,2 %	29,8 %
2	290 704	145 351	423 529	0,8505	16,6 %	32,6 %
3	436 055	145 351	391 514	0,8697	14,7 %	36,5 %
Snitt			420 291	0,8509	16,5 %	33,0 %


genomsnittet från korsvalideringen (MdAPE 16,5 %) är förväntat, eftersom slutmodellen tränas på mer data och använder hyperparametrar optimerade för hela datasetet.

6.5 Lokal SHAP och transparensrapport

Vid varje värdering kan en lokal SHAP-uppdelning av prediktionen samt en transparensrapport beräknas för en enskild fastighet. Detta ger användaren ett underlag för att bedöma både hur värderingen är konstruerad och hur tillförlitlig den är. Bakgrunden och implementationen beskrivs i avsnitt 5, här presenteras den slutgiltiga utformningen.

Figur 4 visar den lokala SHAP-grafen för en enskild värdering, så som den genereras i användargränssnittet (se avsnitt 5.20 för detaljer). Grafen utgår från modellens basvärde och redovisar hur varje variabel adderar eller drar ifrån i kronor tills slutprediktionen nås. Variablerna är sorterade efter absolut bidrag, vilket gör att de mest avgörande prisdrivarna för just den aktuella fastigheten alltid hamnar överst. Detta gör att samma modell kan motivera två olika värderingar på olika sätt, beroende på om priset i ett enskilt fall främst styrs av läge, boarea, taxeringsuppgifter eller en tidigare försäljning.

De lokala SHAP-värdena presenteras också i en tabell i användargränssnittet. Denna tabell kan användaren ladda ner som en Excel-fil för närmare inspektion.




Figur 4: Lokal SHAP-uppdelning för en enskild värdering. Varje stapel visar variabelns bidrag i kronor.

Den lokala SHAP-grafen kompletteras av en transparensrapport som genereras automatiskt i samma vy. Rapporten sammanfattar kontextuell information, exempelvis vilka försäljningar som ligger till grund för de lokala prisankarna (*KNN_Price_m2* och *Area_median_m2*), hur långt tillbaka i tiden dessa sträcker sig, samt om någon variabel saknas. Se figur 5 nedan (för mer detaljer se föregående kapitel 5). Som komplement redovisar rapporten även transaktionsvolymtrender över tid på både kommun- och distriktsnivå, se figur 6 och figur 7, vilket gör det möjligt för användaren att avgöra om de lokala prisankarna bygger på en stabil eller en krympande marknad.


Jämförbara försäljningar (10 närmaste grannar)					
Avstånd	Pris/m ²	BOA	Est. pris	Datum	Beteckning
20 m	73,260 kr	112 m ²	8,205,120 kr	2018-09	
50 m	50,018 kr	185 m ²	9,253,330 kr	2020-03	
50 m	51,874 kr	204 m ²	10,582,296 kr	2022-09	
70 m	61,624 kr	152 m ²	9,366,848 kr	2024-01	
80 m	64,713 kr	176 m ²	11,389,488 kr	2021-08	
90 m	54,634 kr	140 m ²	7,648,760 kr	2022-11	
100 m	56,548 kr	160 m ²	9,047,680 kr	2024-04	
100 m	60,897 kr	177 m ²	10,778,769 kr	2022-05	
110 m	49,486 kr	143 m ²	7,076,498 kr	2022-08	
120 m	78,242 kr	124 m ²	9,702,008 kr	2020-08	

Områdesstatistik	
Antal försäljningar i träningsdata	
• Distrikt: Limhamn distrikt	— 1,304 försäljningar
• Kommun: Malmö kommun	— 6,619 försäljningar
Medianpris per m² (tidsjusterat)	
• Hela Sverige:	27,884 kr/m ²
• Malmö kommun:	46,366 kr/m ²
• Limhamn distrikt:	61,100 kr/m ²

Figur 5: Transparensrapport som genereras vid varje värdering. Rapporten kompletterar den lokala SHAP-grafen med information om datatäthet, datafärskhet och eventuella saknade variabler.



Figur 6: Försäljningsvolym per år i den aktuella kommunen i transparensrapporten.



Figur 7: Försäljningsvolym per år i det aktuella distriktet i transparensrapporten.

Tillsammans gör de fyra komponenterna att modellens utdata inte behöver tas emot som en black box. Figur 4 visar vad som driver priset, medan figur 5, figur 6 och figur 7 visar hur mycket data värderingen vilar på och hur marknaden ser ut lokalt. När bidragen fördelas över flera variabler och datatätheten är god kan värderingen ses som mer tillförlitlig. Domineras den istället av en enskild variabel, eller bygger på få och avtagande försäljningar, bör den granskas mer kritiskt.

6.6 Global SHAP-analys

Tabell 18 visar en global SHAP-analys av värderingsmodellen, beräknad på 5 000 slumpmässigt utvalda transaktioner från hela datasetet. Värdena anges i log-skala (naturlig logaritm av priset) och i kronor, och utgör genomsnittliga absolutbelopp, det vill säga hur mycket varje variabel typiskt påverkar prediktionen i kronor oavsett riktning. Modellens basvärde är utgångspunkten innan variablernas bidrag adderas.

Tabell 18: Global SHAP feature-importance, 5 000 slumpmässiga transaktioner.

#	Variabel	Bidrag (log)	Bidrag (kr)
	<i>Basvärde</i>	14,6955	2 410 775
1	Area_Median_m2	0,2831	707 156
2	KNN_Price_m2	0,1513	354 392
3	Prev_Sale_Price	0,1172	303 900
4	BOA (m ²)	0,1222	290 902
5	Kommun_code	0,0811	193 093
6	Prev_Sale_Months_Ago	0,0657	152 989
7	Standardpoäng	0,0587	140 022
8	Kontrakt_Tidsindex	0,0505	122 479
9	Belägenhet_code	0,0382	98 730
10	Värdeår	0,0337	82 264
11	Byggår	0,0309	75 941
12	Värdearea (m ²)	0,0271	64 768
13	Energiklass_code	0,0262	63 375
14	Tomtareal (m ²)	0,0260	63 138
15	Avlopp_code	0,0153	36 615
16	Bolåneränta	0,0150	36 315
17	KPI	0,0122	29 516
18	latitude	0,0117	27 940
19	Vatten_code	0,0110	26 432
20	Tax. BIA (m ²)	0,0109	26 274
21	longitude	0,0095	22 757
22	Bebyggelseyp_code	0,0088	21 172
23	Typkod	0,0035	8 223
24	Arbetslöshet	0,0025	5 996
25	Tomträtt_code	0,0014	3 270
26	Nyproduktion_code	0,0007	1 608

Att *Area_Median_m2* och *KNN_Price_m2* ligger i topp är väntat. Den första är medianpriset per kvadratmeter i det område fastigheten ligger i, och den andra är ett viktat snittpris per kvadratmeter från de mest lika fastigheterna (K-Nearest Neighbour). Båda fångar läge och lokal prisnivå, vilka traditionellt är de viktigaste prisdrivarna inom fastighetsvärdering (Lind 2014; Freeman III, Herriges och Kling 2014). Även *Prev_Sale_Price* (tidigare försäljningspris) och *BOA* (boarea) hamnar högt, vilket också är förväntat.

I botten ligger *Nyproduktion_code* och *Tomträtt_code*. Det beror på att kategorierna utgör en mycket liten del av datasetet, endast 0,37 % av objekten är nyproduktion och 2,06 % har tomträtt. Eftersom bidraget snittas över alla 5 000 observationer blir det lågt, även om effekten kan vara större i de enskilda fall där variabeln är aktuell.

Tabellen beskriver alltså ett globalt snitt över hela datasetet. För enskilda fastigheter och delmarknader kan rangordningen se mycket annorlunda ut, men detta är hur bidragen typiskt fördelar sig.

6.7 Värdering av enskilda fastigheter: två stickprov

För att utvärdera modellens prediktiva förmåga i praktiken har två separata stickprov genomförts. I det första stickprovet (20 fastigheter) jämförs Movton med två etablerade referensmodeller, Boolis AVM och Värderingsdatas *Pris idag*, samt med faktiskt slutpris. I det andra stickprovet (10 fastigheter) utvärderas modellen rent prediktivt mot fastigheter som sålts strax efter att träningsdatan tar slut (2026-04-09), och som därmed inte ingår i modellens underlag.

Fastigheterna valdes genom en kombination av medvetet urval och slump. Först säkerställdes en spridning över olika typer av områden, såsom storstäder, mindre städer och landsbygd, för att ge en representativ bild av Sverige. Inom dessa områden valdes enskilda fastigheter slumpmässigt, men urvalet kompletterades också medvetet med ett antal svårvärderade objekt, exempelvis fastigheter med ovanligt stor tomt, oklara taxeringsuppgifter eller objekt i extrema prissegment. Syftet var att pröva modellen i fall där även etablerade referensmodeller kan förväntas brottas med värderingen, och inte enbart mäta prestanda på enkla, homogena objekt.

Av integritets- och dataskyddsskäl redovisas fastigheterna i stickproven endast med en kod (A1-A20 respektive B1-B10) tillsammans med kommun och BOA. Adresser, fastighetsbeteckningar och distrikt utelämnas för att inte offentliggöra uppgifter som kan kopplas till nuvarande eller tidigare ägare.

Det bör understrykas att de två stickproven har ett annat syfte än prestandamåtteten i avsnitt 6.3. Medan MdAPE och R2 vilar på hundratusentals observationer, bygger de enskilda fallen på ett begränsat antal fastigheter. Stickproven är därför främst avsedda att illustrera var modellen antagligen fungerar väl respektive mindre väl, och att generera uppslag för fortsatt förbättring, snarare än att fastställa systematiska slutsatser om modellens begränsningar. När vi i de enskilda fallen lyfter fram en trolig förklaring till en avvikelse, ska detta läsas som en hypotes om en möjlig förbättringsväg snarare än som ett fastställt orsakssamband. Att en enskild avvikelse sammanfaller med en viss egenskap hos objektet utesluter inte andra förklaringar, och varje fall innehåller en grad av osäkerhet som inte låter sig kvantifieras på samma sätt som de aggregerade måtten. Fallens främsta värde ligger därför inte i att de bevisar något om modellens svagheter, utan i att de genererar konkreta och prövbara uppslag för fortsatt utveckling.

6.7.1 Referensmodeller

Booli AVM

Boolis automatiska värderingsmodell bygger enligt deras egen beskrivning på en kombination av linjär regression och en boostingbaserad maskininlärningsmodell. De använder även referensbaserad kärnregression (kernel regression) som tränas med en genetisk algoritm. Modellen kompletteras med justeringar för tidigare försäljningar av samma bostad samt för objektets skick.

Värderingsdata (Pris idag)

Värderingsdata anger ett *Pris idag* för en fastighet genom att tidsjustera tidigare observerade transaktioner med ett egenutvecklat prisindex. Indexet beräknas genom att värdera bostaden vid en specifik referensmånad och jämföra med försäljningspriset vid försäljningstillfället; den aggregerade prisförändringen mellan referensmånad och försäljningsmånad bildar indexet. Värderingsdata uppger att de använder egna metoder för att uppnå hög geografisk och tidsmässig upplösning, och validerar indexet genom jämförelse mot publika prisindex. Exakt metodik publiceras inte.

6.7.2 Stickprov 1: jämförelse mot Booli och Värderingsdata

Samtliga värderingar i stickprov 1 är gjorda med värderingsdatum 2026-04-20. Tabell 19 visar de 20 fastigheterna med vår värdering, Boolis värdering och Värderingsdatas *Pris idag* per samma datum. För varje objekt redovisas också det faktiska slutpriset samt den procentuella avvikelser mellan Movton och respektive referens. Medianen är +2,6 % mot Booli och +7,5 % mot Värderingsdata, vilket kan tyda på en svag tendens att Movton värderar något högre än referenserna i detta stickprov. MdAPE är 8,7 % mot Booli respektive 9,5 % mot Värderingsdata.

Tabell 19: Stickprov 1 - Movton jämfört med Booli och Värderingsdata.

Kod	Kommun	BOA (kvm)	Movton	Booli	VD	Slutpris	Kontrakt	ΔBooli	ΔVD
A1	Malmö	110	8 450 000	8 250 000	8 364 000	8 700 000	2022-02-03	2,4 %	1,0 %
A2	Stockholm	132	6 550 000	5 700 000	5 550 000	5 555 000	2025-11-21	14,9 %	18,0 %
A3	Sundsvall	216	2 420 000	2 650 000	2 350 000	2 245 000	2020-09-08	-8,7 %	3,0 %
A4	Umeå	175	5 830 000	5 760 000	5 799 000	4 900 000	2019-04-27	1,2 %	0,5 %
A5	Göteborg	171	12 930 000	12 600 000	13 069 000	13 000 000	2024-09-06	2,6 %	-1,1 %
A6	Växjö	129	3 900 000	3 590 000	3 492 000	3 250 000	2020-01-31	8,6 %	11,7 %
A7	Ljungby	122	1 900 000	1 920 000	1 312 000	1 200 000	2018-11-29	-1,0 %	44,8 %
A8	Grums	116	2 170 000	1 490 000	1 988 000	2 000 000	2023-06-20	45,6 %	9,2 %
A9	Åsele	119	500 000	500 000	372 000	250 000	2018-03-03	0,0 %	34,4 %
A10	Linköping	75	4 100 000	4 160 000	4 218 000	3 780 000	2019-03-07	-1,4 %	-2,8 %
A11	Eslöv	154	5 300 000	4 650 000	4 878 000	5 145 000	2022-06-27	14,0 %	8,7 %
A12 ^a	Nacka	243	16 750 000	15 500 000	15 266 000	14 500 000	2023-05-16	8,1 %	9,7 %
A12 ^b	Nacka	203	16 000 000	15 400 000	-	14 500 000	2023-05-17	3,9 %	-
A13	Mölndal	94	4 910 000	4 800 000	4 850 000	4 850 000	2026-03-31	2,3 %	1,2 %
A14	Uppsala	179	6 410 000	5 740 000	6 029 000	6 320 000	2022-05-27	11,7 %	6,3 %
A15	Åre	100	8 400 000	9 600 000	9 962 000	9 000 000	2021-07-07	-12,5 %	-15,7 %
A16	Kiruna	120	1 270 000	2 480 000	788 000	600 000	2018-06-08	-48,8 %	61,2 %
A17	Skellefteå	118	4 250 000	3 710 000	4 132 000	3 995 000	2023-10-16	14,6 %	2,9 %
A18	Filipstad	122	1 010 000	830 000	854 000	800 000	2023-05-17	21,7 %	18,3 %
A19	Vellinge	176	15 000 000	17 900 000	17 783 000	16 500 000	2020-12-02	-16,2 %	-15,6 %
A20	Borås	229	6 890 000	4 950 000	4 932 000	5 000 000	2022-10-04	39,2 %	39,7 %
Median								2,6 %	7,5 %
Median (absolut)								8,7 %	9,5 %

^a BOA enligt annons/Värderingsdata: 243 kvm. ^b BOA enligt taxeringsuppgift: 203 kvm.
Belopp i kr. Värderingsdatum 2026-04-20 för samtliga objekt.

Tabell 19 visar att Movton i stora drag ligger nära de två referensmodellerna. Samtidigt syns större avvikelser i vissa objekt, särskilt där fastigheterna har ovanliga egenskaper eller ligger i mer svårbedömda segment.

Korta noteringar (stickprov 1) Tabell 20 sammanfattar de övriga objekten i stickprov 1 där modellens värdering ligger nära referenserna eller inte motiverar någon längre kommentar. Tabellen är tänkt att ge en överblick över vilken typ av fastighet och marknadssegment varje kod representerar.

Tabell 20: Stickprov 1 - korta noteringar för övriga objekt.

Kod	Notering
A1	Malmö, något lyxigare segment.
A3	Vanlig villa i Sundsvall.
A4	Vanlig villa i Umeå.
A5	Lyxvilla i Göteborg.
A6	Vanlig villa i Växjö-förort.
A10	Villa strax utanför Linköping.
A11	Central villa i Eslöv.
A13	Radhus i Mölndal sålt 2026-03, nära både Booli och slutpris.
A14	Villa relativt centralt i Uppsala.
A17	Villa nära centrala Skellefteå.

Längre observationer (stickprov 1)

A2 - Stockholm, vanlig villa där Movton avviker uppåt mot ett färskt slutpris.

Movton värderar fastigheten till 6 550 000 kr, vilket är ca 15 % högre än Booli och 18 % högre än Värderingsdata. Båda referenserna är inbördes överens (5 700 000 kr respektive 5 550 000 kr), och slutpriset på 5 555 000 kr från 2025-11 ligger mycket nära dessa nivåer. Eftersom slutpriset endast är cirka fem månader före värderingsdatumet utgör det ett relativt tillförlitligt referensvärde, och Stockholm är dessutom en marknad med tätt transaktionsunderlag där samtliga modeller normalt har god prediktiv förmåga. Detta är därmed ett fall där förklaringar kopplade till tunt jämförelseunderlag eller inaktuell data inte är särskilt rimliga. En möjlig förklaring är istället att Movton saknar information om någon specifik negativ egenskap hos objektet, i likhet med fallet B5 (Bromma, radonhus) som behandlas senare i stickprov 2. Det går heller inte att utesluta att Movton fångar någon kvalitetsegenskap hos fastigheten som referensmodellerna missar, även om detta framstår som mindre sannolikt givet att både Booli, Värderingsdata och ett färskt slutpris pekar mot samma nivå.

A7 - Ljungby, vanlig villa där Värderingsdata avviker nedåt.

Movton och Booli ger nästan identiska värderingar (1 900 000 kr respektive 1 920 000 kr), medan Värderingsdata hamnar ca 45 % lägre på 1 312 000 kr. Slutpriset från 2018-11 är drygt sju år gammalt och utgör inget tillförlitligt referensvärde för dagens nivå. Att två oberoende AVM:er landar på samma nivå talar för att Movtons värdering är rimlig, och att det i detta fall snarare är Värderingsdata som avviker. En möjlig förklaring är att Värderingsdatas tidsjusterade indexmetod är känsligare för tunt jämförelseunderlag i mindre orter som Ljungby, där få transaktioner kan ge stora utslag i det lokala prisindexet.

A8 - Grums, vanlig villa med stor avvikelse mot Booli.

Movton hamnar ca 46 % högre än Booli men endast 9 % högre än Värderingsdata, och 8,5 % över slutpriset från 2023-06. Att Booli ligger så pass mycket under både slutpris och övriga modeller är anmärkningsvärt, eftersom Booli har tillgång till en bred transaktionshistorik och normalt fångar upp lokala prisnivåer väl. En rimlig tolkning är att Booli väger in någon specifik egenskap hos fastigheten som varken Movton eller Värderingsdata har information om, exempelvis skick, planlösning eller andra objektsspecifika faktorer som inte återspeglas i de variabler Movton använder.

A9 - Åsele, vanlig villa i mycket avlägset läge.

Movton och Booli ger identiska värderingar på 500 000 kr, medan Värderingsdata hamnar ca 34 % lägre på 372 000 kr. I likhet med fallet A7 (Ljungby) talar två oberoende AVM:er som landar på samma nivå för att Movtons värdering är rimlig, och att det snarare är Värderingsdata som avviker. Att fastigheten ligger i ett mycket avlägset läge i Norrlands inland gör jämförelseunderlaget särskilt tunt, vilket sannolikt förstärker den effekt som beskrevs för A7, där få lokala transaktioner kan ge stora utslag i Värderingsdatas prisindex.

A12 - Nacka, attraktivt pendelläge med oklar BOA.

Fastigheten ligger i ett attraktivt och relativt lyxigt segment, och vår modell hamnar i det högre spannet av referenserna. En väsentlig osäkerhet är att BOA enligt annons och Värderingsdata anges till 243 kvm, medan taxeringsuppgifterna anger 203 kvm. När Booli matas med 203 respektive 243 kvm ändras värderingen endast med ca 100 000 kr, vilket kan tyda på att Boolis modell främst stödjer sig på egen data snarare än på den BOA som användaren matar in. Movton värderar däremot 16 000 000 kr vid 203 kvm och 16 750 000 kr vid 243 kvm. Vilken nivå som är mest korrekt är svårt att avgöra utan att först veta vilken BOA som faktiskt stämmer. Fallet illustrerar främst hur osäker indatakvalitet (BOA) kan påverka värderingar.

A16 - Kiruna (Tuolluvaara), mycket stor tomt.

De tre modellerna ger mycket olika värderingar och det är svårt att avgöra vilken som är mest rimlig. Tomten är väldigt stor, cirka 74 000 kvm, vilket inte är representativt för ett typiskt småhus. Fastigheten är taxerad som småhus men liknar i karaktär en lantbruksenhet, vilket sannolikt försvårar prediktion för samtliga modeller.

A18 - Filipstad, mindre ort där Movton avviker uppåt.

Movton hamnar ca 22 % högre än Booli och 18 % högre än Värderingsdata, medan båda referensmodellerna är ganska överens (830 000 kr respektive 854 000 kr). Slutpriset från 2023-05 ligger på 800 000 kr, alltså nära referenserna. Att två oberoende AVM:er och ett relativt aktuellt slutpris alla pekar mot samma nivå talar för att det i detta fall är Movton som värderar för högt. En möjlig förklaring är att modellen har svårare att kalibrera prisnivåer i mindre orter med tunna-

re transaktionsunderlag. Det går samtidigt inte att utesluta det omvända, att Movton fångar någon kvalitetsegenskap hos fastigheten som de andra modellerna missar och som motiverar en högre värdering. Fallet liknar i denna mening A7 och A9, men med omvänt utfall: där Movton tidigare gynnats av att två AVM:er landat på samma nivå, är det här Movton som står ensam mot referenserna.

A19 - Höllviken, lyxvilla nära strand.

176 kvadratmeter BOA, attraktivt läge inom 150 meter från strand. Movton hamnar lägre än både Booli och Värderingsdata (-16% respektive -15%). En möjlig förklaring är att modellen har svårare att fånga lägespremier i de övre prissegmenten, men andra orsaker kan inte uteslutas. Det bör även noteras att det omvända scenariot är möjligt, att Booli och Värderingsdata övervärderar fastigheten. Som med alla värderingar finns inget objektivet ”rätt” svar, utan enbart olika grader av rimlighet.

A20 - Borås, vanlig villa med relativt hög BOA.

Movton hamnar ca 39% högre än både Booli och Värderingsdata. SHAP-analysen tilldelar BOA det största positiva bidraget, vilket i sig är rimligt. Värderingen av Movton kan upplevas som väldigt hög givet att försäljningen 2022-04 låg nära fastighetsmarknadens trendtopp, men avvikelserna kan ha flera orsaker, t.ex. hur modellen viktar BOA i kombination med övriga attribut, eller egenskaper som inte fångas i indatan.

Noteringar om nyligen sålda objekt

Fastigheter som sålts inom de senaste 3 månaderna (t.ex. A13) är ur ett utvärderingsperspektiv begränsat informativa eftersom slutpriset i sig är en mycket aktuell marknadsindikation. Dessa typer av försäljningar har ändå tagits med i stickprovet i begränsat antal för att illustrera att modellen producerar rimliga värderingar även när transaktionen är färsk, utan att modellen nödvändigtvis återskapar exakt slutpriset.

6.7.3 Stickprov 2: rent prediktiv utvärdering

Samtliga värderingar i stickprov 2 är gjorda med värderingsdatum 2026-04-26. Detta stickprov utgår från fastigheter som sålts *efter* att modellens träningsdata avslutats 2026-04-09 men före värderingsdatumet 2026-04-26. För dessa har modellen ingen tidigare försäljning av objektet att stödja sig på, och varken Booli eller Värderingsdata används som referens eftersom dessa har tillgång till tidigare försäljning. Tabell 21 jämför därför enbart med faktiskt slutpris samt utgångspris. MdAPE:n för Movton mot slutpriset är i detta stickprov 13,2%, vilket ligger nära modellens prestanda 13,0% (avsnitt 6.3).

Makroekonomisk kontext

Stickprov 2 utfördes direkt efter SCB:s släpp av arbetslöshetssiffror för mars

2026. Säsongrensad arbetslöshet låg på 9,4 %, en ökning med cirka 1 procentenhet jämfört med föregående månad. Det är en makroekonomisk händelse som potentiellt påverkar modellens värderingar, även om arbetslöshet har en relativt låg vikt i den globala SHAP-analysen (tabell 18).

Tabell 21: Stickprov 2 - rent prediktiv utvärdering mot slutpris.

Kod	Kommun	BOA (kvm)	Movton	Slutpris	Utg.pris	Värd.dat.	Kontrakt	Δ utg./slut	Δ Movton/slut
B1	Malmö	142	10 110 000	10 250 000	10 800 000	2026-04-26	2026-04-17	-5,1 %	-1,4 %
B2	Växjö	129	3 200 000	3 650 000	3 950 000	2026-04-26	2026-04-21	-7,6 %	-12,3 %
B3	Skövde	112	1 670 000	1 775 000	1 895 000	2026-04-26	2026-04-16	-6,3 %	-5,9 %
B4	Lund	206	8 560 000	7 500 000	7 795 000	2026-04-26	2026-04-18	-3,8 %	14,1 %
B5	Stockholm	140	8 970 000	6 420 000	6 195 000	2026-04-26	2026-04-24	3,6 %	39,7 %
B6	Örnsköldsvik	130	2 180 000	2 630 000	2 675 000	2026-04-26	2026-04-18	-1,7 %	-17,1 %
B7	Uppsala	126	4 310 000	4 000 000	4 150 000	2026-04-26	2026-04-26	-3,6 %	7,7 %
B8	Markaryd	160	1 200 000	700 000	900 000	2026-04-26	2026-04-25	-22,2 %	71,4 %
B9	Linköping	155	4 400 000	4 125 000	3 995 000	2026-04-26	2026-04-26	3,3 %	6,7 %
B10	Göteborg	78	4 950 000	5 925 000	5 850 000	2026-04-26	2026-04-11	1,3 %	-16,5 %
<i>Median</i>								-3,70 %	2,65 %
<i>Median (MdAPE)</i>								3,70 %	13,20 %

Tabell 21 visar att modellen även i ett rent prediktivt test ligger på en nivå som är jämförbar med dess övergripande prestanda. Avvikelserna tycks främst uppstå i objekt där viktiga egenskaper inte fångas fullt ut av indata.

Korta noteringar (stickprov 2) Tabell 22 sammanfattar de objekt i stickprov 2 som inte motiverar någon längre kommentar.

Tabell 22: Stickprov 2 - korta noteringar.

Kod	Notering
B1	Fint läge i Västra hamnen, radhus.
B2	Teleborg, strax utanför Växjö, vanlig villa.
B3	Värsås (mindre ort), vanlig villa, cirka 170 km från Göteborg.
B4	Fin villa i norra Nöbbelöv, Lund.
B7	Standardkedjehus i Uppsala (Sävja).
B9	Vanlig villa i Vikingstad, pendelort till Linköping.

Längre observationer (stickprov 2)

B5 - Stockholm (Bromma), radonhus.

Denna fastighet såldes för 6,42 Mkr. En tydlig avvikelse jämfört med omgivning-
en eftersom närliggande fastigheter har sålts för kring 7-8 Mkr, men det aktuella
objektet är ett konstaterat radonhus enligt fastighetsregistret (tillräckligt höga
värden vid radonmätning), vilket sannolikt påverkar slutpriset nedåt. Detta är
information modellen inte har tillgång till och kan vara en bidragande förklaring
till avvikelsen på 39,7 %.

B6 - Örnsköldsvik, vanlig villa där Movton avviker nedåt.

Movton värderar fastigheten till 2 180 000 kr, vilket är ca 17 % under slutpriset på 2 630 000 kr. Slutpriset ligger nära utgångspriset på 2 675 000 kr, vilket tyder på en normal försäljning utan särskild budgivning. En möjlig förklaring är att modellen saknar information om positiva egenskaper hos objektet, exempelvis skick eller renoveringsstatus, som inte fångas av de tillgängliga variablerna. Fallet illustrerar att modellens svagheter är dubbelriktade, modellen kan både övervärdera objekt med dolda negativa egenskaper och undervärdera objekt med dolda positiva egenskaper.

B8 - Markaryd, slitet hus.

Relativt centralt i Markaryd men i slitet skick. Modellen hamnar på 1,2 Mkr mot slutpriset 0,7 Mkr. Bedömningen är att 0,9 Mkr (utgångspris) framstår som mer rimligt, men detta är en subjektiv bedömning. En egendomlighet är att fastigheten enligt Boverket har energiklass B trots byggår 1940 (tillbyggt 1993, värdeår 1953). I SHAP bidrar energiklass B med ca +350 000 kr; sätts energiklassen till okänd eller F värderas fastigheten till 957 000 kr. Energideklarationen är från 2025-11-13. Det kan röra sig om en datakvalitetsanomal i Boverkets register, men illustrerar oavsett hur beroende modellen kan vara av enskilda inputvariabler för udda objekt.

B10 - Göteborg (Härlanda), 78 kvm.

Movtons värdering ligger cirka 16,5 % under slutpriset, vilket antagligen innebär en undervärdering. SHAP-analysen visar att BOA och värdearea (cirka -550 000 kr), standardpoäng (-105 000 kr) och tomtareal (-87 000 kr) är de variabler som drar ned värderingen mest. En möjlig förklaring är att standardpoängen i taxeringsuppgifterna, som anges till 25, inte fullt ut speglar fastighetens faktiska skick givet den moderna interiören och exteriören som framgår av annonsen. Fastigheten följer ett mönster som återkommer i området: centralt och attraktivt läge kombinerat med liten boarea relativt övriga staden, vilket gör att flera av modellens viktigaste variabler samverkar nedåt. Movton kan ha en svaghet i denna typ av fall, där attraktivt läge kombineras med låg boarea. Dessutom är standardpoängen ett aggregerat mått som delvis samvarierar med boyta, ett mindre hus har helt enkelt inte utrymme för samma antal rum och faciliteter som ett större, vilket ger lägre standardpoäng oavsett faktiskt skick. Modellen kanske inte fångar denna distinktion. En indatavariabel med mer precis information om fastighetens skick, oberoende av storlek, hade sannolikt förbättrat värderingen i fall som detta.

7 Diskussion

7.1 Hur fungerar AI-baserade värderingsmodeller?

I princip alla AI-baserade värderingsmodeller för fastigheter vilar på en gemensam teoretisk grund. I grunden försöker samtliga modeller identifiera någon form av statistiskt samband mellan observerbara fastighetsattribut och historiska transaktionspriser. Dessa samband kan vara linjära eller icke-linjära. De kan även modelleras antingen explicit, exempelvis genom regressionsmodeller, eller implicit genom mer komplexa maskininlärningsmetoder. En modell tränas vanligtvis på ett stort antal tidigare försäljningar där varje observation beskrivs av ett antal variabler (features). Variablerna utgörs typiskt av relevant och kvantifierbar fastighetsdata, exempelvis boarea, byggår, geografiskt läge etc. De kan även inkludera mer kontextuella variabler av mer makroekonomisk karaktär såsom arbetslöshet, kreditvillkor och räntenivåer. Under träningsprocessen estimeras de underliggande relationerna mellan variablerna och de observerade transaktionspriserna. Den resulterande modellen kan därefter tillämpas för att prediktera marknadsvärden för nya objekt, givet deras observerbara egenskaper.

Modellen utvecklad i detta arbete bygger på en gradient boosting-metod, XGBoost. XGboost bygger sekventiellt upp ett stort antal beslutsträd. Beslutsträdet bygger på residualer. Varje träd tränas på residualerna från föregående träd, det vill säga de fel som kvarstår, vilket gör att modellen successivt förfinar sina prediktioner. De grundläggande sambanden, exempelvis att en större boyta eller ett mer centralt läge korrelerar med ett högre pris, fångas upp tidigt i träningsprocessen. Därefter tillkommer beslutsträd som hanterar mer subtila och komplexa samband, som till exempel samspelet mellan bolåneräntor och prisnivåer i olika geografiska segment. En central utmaning i fastighetsvärdering generellt är att fånga det lokala priset för fastigheter på ett meningsfullt sätt. I denna modell har vi valt att göra det i form av koordinater. Latitud och longitud ger modellen geografisk precision men säger inte i sig något om prisnivån i ett område. För att ge modellen ett tydligt prisankare konstruerades därför tre kompletterande variabler. ett tidsjusterat distriktsmedianpris, ett grannskapsbaserat KNN-prisankare baserat på de tio geografiskt närmaste försäljningarna, samt eventuellt tidigare försäljningspris för samma fastighet. Dessa variabler visade sig vara bland de viktigaste i modellen och illustrerar ett grundläggande drag hos AI-baserade värderingsmodeller, modellens förmåga bestäms i stor utsträckning inte enbart av algoritmen i sig, utan av kvaliteten och relevansen hos de variabler som matas in. För att modellen ska vara användbar inom fastighetsvärdering räcker det dock inte att den predikterar ett korrekt värde. Värderingen måste även gå att granska och motivera. I detta arbete hanteras detta genom att kombinera XGBoost med SHAP-värden. Att kombinera modellen med SHAP-värden gör modellen till en explainable AI. SHAP möjliggör att varje enskild prediktion kan brytas ned i additiva bidrag per variabel, uttryckta i kronor. En användare kan därmed direkt avläsa att boarean bidrar med exempelvis +850 000 kronor till värderingen, medan det rådande ränteläget drar ned densamma med 40 000 kronor. Det gör modellen transparent på ett sätt som en renod-

lad black box-modell inte medger, och möjliggör en professionell granskning av enskilda värderingar.

Som tidigare forskning visar finns det aspekter där traditionell värdering överpresterar AI-baserade modeller och tvärtom. Under stabila marknadsförhållanden uppvisar erfarna värderare en lägre medianabsolut procentuell avvikelse än AVM-modeller, medan skillnaderna tenderar att minska under mer dynamiska marknadsperioder (Birkeland m. fl. 2021). Den naturliga slutsatsen är att hybridmodeller då rimligtvis är den optimala lösningen där både AI och mänsklig expertis kombineras för att nyttja styrkorna hos båda. I praktiken tar hybridmodeller sig flera olika uttryck. I det enklaste fallet används en AVM som ett första steg för att generera ett indikativt värdeintervall, varefter en certifierad värderare granskar och justerar utfallet baserat på information som modellen inte kan fånga. Denna information är exempelvis en nyligen renoverad interiör, ett ovanligt planlösningsdrag eller en pågående stadsomvandling i området. Detta tillvägagångssätt effektiviserar värderingsprocessen utan att helt avhända sig det mänskliga omdömet. En mer avancerad hybridlösning bygger på compound AI-system. De bygger på flera specialiserade AI-modeller som samverkar för att hantera olika delar av processen. En delmodell kan exempelvis ansvara för bildanalys av exteriör- och interiörbilder, en annan för analys av marknadsdata och en tredje för automatisk rapportskrivning och en övergripande modell väger samman resultaten. En variant av detta implementerades även i detta arbete i form av en lyxmodell som aktiveras vid högt värderade objekt och blandas in gradvis med grundmodellens prediktion via en viktad övergångsfunktion. Principen är densamma som i stacked generalization, där olika modellens prediktioner kombineras till ett sammansatt utfall baserat på hur väl respektive modell presterar i det aktuella värderingssegmentet. En annan praktisk form av hybridisering är Agentic AI, där ett AI-system självständigt söker i databaser, hämtar marknadsinformation och utför preliminära analyser, varefter resultaten presenteras för en värderare som fattar det slutgiltiga beslutet. I detta upplägg förändras värderarens roll från att manuellt samla in och sammanställa underlag till att granska, tolka och kvalitetssäkra ett maskinellt förberett material. Icke-rutinmässiga bedömningar, kundkontakt och professionellt ansvar förblir mänskliga domäner, medan det tidskrävande datainsamlingsarbetet automatiseras.

Sammantaget fungerar AI-baserade värderingsmodeller som ett datadrivet system för mönsterigenkänning i transaktionsdata. Deras styrka ligger i förmågan att hantera stora datamängder, identifiera icke-linjära samband och ge konsekventa värderingar utan den individuella bias som präglar mänskliga värderare. Begränsningarna är lika tydliga. Modellen blickar alltid bakåt, är beroende av datakvaliteten och kan aldrig fullt ut fånga de diskreta och framtidsblickande bedömningar som en erfaren värderare gör när marknadsförhållandena förändras snabbt. Hybridmodeller framstår därför inte enbart som en kompromiss utan snarare som det tillvägagångssätt som bäst speglar hur AI och mänsklig kompetens kompletterar varandra i praktiken.

Vad gäller frågan om hur väl en AI-baserad värderingsmodell presterar ger detta

arbetes resultat en nyanserad bild. Modellen uppnådde ett MdAPE på 13 % och ett r^2 -värde på 0,871 på testdata, vilket innebär att hälften av alla prediktioner avviker med mindre än 13 % från det faktiska försäljningspriset och att modellen förklarar cirka 87 % av prisvariationen. För att sätta detta i relation till tidigare forskning bör det understrykas att vissa (Birkeland m. fl. 2021) rapporterar ett MdAPE på 5,4 % för en AVM under stabila marknadsförhållanden, vilket vid en ytlig jämförelse kan verka som en avsevärd skillnad. Jämförelsen är dock inte helt rättvisande. Vår modell Movton tränas och utvärderas på över 600 000 försäljningar spridda över hela Sverige och en tidsperiod som innefattar både kraftiga prisuppgångar, en markant nedgång och en efterföljande återhämtning, marknadsförhållanden som sammantaget är väsentligt mer heterogena än de som präglar de flesta referensstudierna. Att en nationell modell med bred geografisk och tidsmässig täckning uppvisar ett högre MdAPE än en mer avgränsad modell är därmed snarare ett förväntat utfall än ett tecken på bristande modellkvalitet. Resultaten tyder sammantaget på att det inom ramen för begränsade resurser är möjligt att bygga en AI-baserad värderingsmodell med rimlig prediktiv förmåga, men också att precisionen sannolikt kan förbättras avsevärt genom mer granulära delmodeller, utökad variabeluppsättning och tillgång till större beräkningsresurser.

Utöver de aggregerade måtten ger de två stickprov om sammanlagt 30 värderingar som genomfördes i avsnitt 6.7 en mer praktiskt orienterad bild av modellens prestanda. I stickprov 1, där modellen ställdes mot Boolis AVM och Värderingsdatas *Pris idag*, var MdAPE 8,7 % mot Boolis och 9,5 % mot Värderingsdata, vilket är jämförbart med de etablerade referensmodellernas inbördes spridning och därmed talar för att modellen håller en rimlig nivå även i en marknadsmässig jämförelse. I stickprov 2, som utgjorde en rent prediktiv utvärdering mot fastigheter sålda efter att träningsdatan tagit slut, hamnade MdAPE mot slutpriset på 13,2 %, vilket ligger nära modellens MdAPE på testdata (13 %) och stärker bilden av att den generaliserar till osedda objekt utan tydligt prestandafall. Stickproven illustrerar samtidigt var modellens svagheter ligger. De största avvikelserna tycks återkomma i objekt med egenskaper som inte fångas av de tillgängliga variablerna, exempelvis radonhus, ovanligt slitet skick eller fastigheter där taxeringsuppgifterna ger en missvisande bild av standarden. Det förstärker bilden av att modellens precision i hög grad bestäms av kvaliteten av indata samt bredden och tillgången till variabeluppsättningen.

7.2 Vilka utmaningar finns i skapandet av AI-baserade värderingsmodeller?

Genom det praktiska arbetet med att utveckla en AI-baserad värderingsmodell har en rad återkommande utmaningar framträtt. Dessa utmaningar är till sin karaktär inte rent algoritmiska. De rör snarare datakvalitet, datatillgång, variabelurval, modellgeneraliserbarhet och de praktiska och resursmässiga ramar inom vilka ett sådant arbete bedrivs. Många av de problem som uppmärksammas i detta arbete bedöms dessutom som generellt giltiga för AI-baserad fastighetsvärdering, och inte enbart specifika för den modell som utvecklats här.

Den första och mest grundläggande utmaningen rör tillgången till data, både i omfattning och i kvalitet. I detta arbete fanns visserligen tillgång till Värderingsdatas ortspristjänst, vilken får anses vara en av de mest fullständiga svenska datakällorna för småhusförsäljningar. Trots detta utgjorde själva insamlingen och bearbetningen av materialet en omfattande del av projektet. Som beskrivits i avsnitt 5.8 medförde tjänstens praktiska begränsningar att nedladdningen av cirka 600 000 transaktioner krävde ett omfattande automatiseringsarbete och resulterade i runt 3 000 separata Excel-filer. Den efterföljande bearbetningen, kvalitetssäkringen och valideringen sträckte sig över ungefär två månaders arbete. Komplexiteten i detta steg ska inte underskattas. En AI-modell tränad på undermålig data ger inga tillförlitliga prediktioner, oavsett vad utvärderingsmåttens antyder, och datakvalitet får därför ses som en förutsättning för all efterföljande modellutveckling.

Med tillkomsten av lokala prisankare (avsnitt 5.15) framträdde ytterligare en utmaning, nämligen behovet av konsekvent skydd mot dataläckage. Variabler som *Area_Median_m2*, *KNN_Price_m2* och *Prev_Sale_Price* bygger samtliga på historisk transaktionsdata och måste därför beräknas uteslutande från träningsplitten. Skulle testradernas priser indirekt få påverka dessa variabler vid träningsstillfället uppstår en falsk indikation på modellens prestanda. Erfarenheten från arbetet visar att läckage-risker av detta slag gömmer sig och är lätta att förbise, särskilt när variablerna konstrueras stegvis och i flera olika skript. En motsvarande lärdom rörde dedupliceringen av närliggande försäljningar i KNN-beräkningen. I områden med nyproduktion eller upprepad omsättning kan en enskild adress förekomma flera gånger i datan, vilket utan motåtgärd hade gjort att en enskild fastighets pris dominerat grannmängden. Båda dessa exempel illustrerar att en betydande del av det faktiska modellarbetet inte handlar om algoritmisk finjustering, utan om att säkerställa att de data modellen tränas på speglar verkligheten på ett oberoende och representativt sätt.

Närliggande denna utmaning är förekomsten av transaktioner som inte återspeglar marknadsvärdet. Som beskrivs i avsnitt 5.16 kvarstod, trots inledande filtrering och rensning, ett betydande antal icke-marknadsmässiga transaktioner. Antagligen närståendeöverlåtelse, dolda andelsöverlåtelse eller tekniska felregistreringar i datasetet. Att dessa avvikelser identifierades berodde i hög grad på att gränssnittet, genom transparensrapporten, visualiserade KNN-grannarna för varje värdering, vilket gjorde det möjligt att upptäcka uppenbart felaktiga prisobservationer. Hade denna insyn saknats är det rimligt att anta att problemet hade förblivit oupptäckt och därmed snedvridit särskilt de lokala prisankarna. Att en så pass stor andel som omkring 4,3 procent av observationerna behövde rensas bort efter en K/T-baserad granskning illustrerar samtidigt att även en väletablerad datakälla kan innehålla en icke försumbar mängd icke-marknadsmässiga försäljningar.

En annan central utmaning rör vilka variabler som faktiskt finns tillgängliga för att beskriva ett objekt. I detta arbete har modellen primärt tillgång till strukturella och geografiska egenskaper, kompletterat med standardpoäng som ett

grovt mått på byggnadens kvalitet. Standardpoängen fångar en del av variationen i invändig och utvändig standard, men skickbedömningar på en finare nivå saknas i datasetet. Information om köksstandard, badrumsskick, balkong eller uteplats, pool och solceller är inte tillgängliga för modellen, trots att flera av dessa attribut sannolikt har en mätbar effekt på köpeskillingen. Tidigare forskning indikerar att bildbaserad analys av interiöra och exteriöra bilder kan tillföra betydande prediktiv kraft i värderingsmodeller, ofta utöver vad som kan fångas av strukturerade variabler. (Poursaeed, Matera och Belongie 2018; Almaas, Oust och Pollestad 2025) Att integrera bildanalys är dock i sig ett omfattande arbete som ligger utanför ramen för detta examensarbete, men det utgör en naturlig riktning för fortsatt utveckling.

Att modellen inte fångar fastighetens exakta skick beror inte på XGBoost i sig, utan på att den informationen helt enkelt saknas i datasetet. En modell blir aldrig bättre än den data den får. Sådan kvalitativ information finns sällan registrerad i strukturerad form och fångas bäst av metoder som kan bearbeta ostrukturerad data, såsom bildanalys baserad på neurala nätverk eller en textanalys av objektbeskrivningens innehåll. Vägen framåt för fältet pekar därför mot en gradvis integration av just de mer komplexa metoder där black box-problematiken, som diskuterades i kapitel 4, är som mest påtaglig. Det innebär att frågorna om transparens och ansvar som detta arbete berör inte blir mindre relevanta över tid, utan tvärtom alltmer relevanta ju mer kapabla framtida värderingsmodeller blir.

En annan utmaning är att taxeringsuppgifter stämmer inte alltid överens med fastighetens faktiska skick. Dessa uppgifter uppdateras vid ny taxering eller när fastighetsägaren själv anmäler en förändring, vilket innebär att en exempelvis omfattande renovering kan dröja innan den slår igenom i taxeringsuppgifterna. Modellen kan därmed komma att värdera en nyligen renoverad fastighet utifrån föråldrade uppgifter om dess standard. Det är en utmaning som är svår att åtgärda inom modellens ramar, då den endast kan utgå från de attribut som faktiskt finns registrerade. Värderingsmodeller som enbart lutar sig mot taxeringsuppgifter finns det en risk för ett systematiskt glapp som innebär att modellen inte fångar vissa betydande ändringar.

En viktig observation från stickproven är att avsaknaden av detaljerade skick- och kvalitetsvariabler ger upphov till fel i båda riktningarna. Modellen kan både övervärdera objekt med dolda negativa egenskaper och undervärdera objekt med dolda positiva egenskaper. Stickproven gav konkreta exempel på båda utfallen. B5 (Bromma) såldes till ett pris cirka 40 % under modellens värdering, antagligen eftersom modellen saknade information om att fastigheten var ett konstaterat radonhus. B10 (Härlanda) undervärderades istället med cirka 17 % i ett attraktivt centralt läge där liten boarea, låg standardpoäng och liten tomtareal samverkade nedåt i modellens prediktion. För en mänsklig köpare i den marknaden väger läget och fastighetens moderna skick sannolikt tyngre än boarean, men modellen fångar inte denna typ av segmentspecifika prioriteringar utan viktar variablerna mer enhetligt. Stickproven antyder därmed att utmaningen inte enbart handlar

om att fler eller bättre variabler hade behövts, utan möjligen också om att modellen inte alltid fångar hur olika egenskaper samspelar i olika marknadssegment, där samma variabel kan ha mycket olika betydelse beroende på sammanhang.

Utöver variabler som rör skick och utrustning saknas även vissa övergripande beskrivande mått. Information om exempelvis driftkostnader och antal rum hade båda kunnat tillföra information som modellen idag delvis behöver härleda indirekt via andra variabler. Driftkostnader skulle bidra med en dimension av faktisk användningskostnad, medan antal rum skulle ge en mer differentierad bild av planlösningen än vad enbart boarea förmedlar.

En vidare utmaning rör hur AI-modeller fångar dynamiska förändringar i ett områdes attraktivitet. Inflyttningstrender, demografisk omflyttning och pågående stadsförnyelse kan ha betydande inverkan på prisutvecklingen i ett distrikt utan att detta nödvändigtvis återspeglas direkt i de strukturella variablerna. I den nuvarande modellen fångas detta indirekt genom att ett ökat antal försäljningar i ett område, kombinerat med tidsindexet och de tidsjusterade prisankarna, ger en signal om områdets utveckling. Det är dock en indirekt signal, och en mer direkt signal av flytt- och befolkningstrender skulle sannolikt ge ett mer responsivt utfall i områden under snabb förändring.

Den kanske mest betydelsefulla strukturella utmaningen i detta arbete har varit modellens geografiska bredd. Modellen har tränats på samtliga småhusförsäljningar i Sverige under en åttaårsperiod, vilket innebär att den ska kunna värdera allt från innerstadsvillor till fastigheter på glesbygden. En sådan bredd ställer höga krav på modellens förmåga att generalisera. Det är rimligt att anta att en mer regionalt avgränsad modell, i likhet med den ursprungliga prototypen för Skåne (avsnitt 5.5), skulle kunna nå högre precision inom sitt område, eftersom variansen i marknadsförhållanden då är mindre. Det MdAPE-värde om 13 procent som modellen uppvisar bör därför tolkas i ljuset av denna bredd. En eventuell förbättring till detta är att flera regionala delmodeller samverkar under en gemensam infrastruktur, vilket sannolikt skulle förbättra modellprestandan.

De praktiska och resursmässiga ramarna i sig är en utmaning. Att bygga en värderingsmodell av denna omfattning är ett tekniskt komplext arbete som omfattar datainsamling, geokodning, variabelkonstruktion, modellträning, utvärdering och utveckling av användargränssnitt. Detta underlättades emellertid avsevärt av att dokumentationen för alla relevanta Python-bibliotek finns fritt tillgänglig, att den vetenskapliga litteraturen inom området håller hög kvalitet, samt av tillgången till AI-genererade kodförslag och lösningar (kapitel 2). Det blev därmed möjligt att lösa de flesta tekniska problem på rimlig tid. Att dessa förutsättningar finns gör tröskeln för att bygga AI-baserade värderingsmodeller lägre än vad den varit historiskt, men det förändrar inte det faktum att kommersiella aktörer med dedikerade team och betydligt större beräkningsresurser sannolikt kan uppnå högre precision än vad som är realistiskt inom ramen för ett examensarbete. Avsikten med detta arbete har inte varit att överträffa dessa aktörer, utan att undersöka vilka utmaningar som faktiskt uppstår, hur de kan hanteras och var

de naturliga begränsningarna ligger.

En ytterligare utmaning är att tillgänglig datorkraft i sig sätter ramar för hur långt en modell kan drivas. Modellen i detta arbete utvecklades till allra största del på en bärbar dator, med hyfsad processorkraft. Det fungerade väl för både databearbetning och träning, men det innebär samtidigt att antalet träningsiterationer, hyperparametersökningar och experimentella varianter fick hållas inom rimliga gränser för att arbetet skulle gå att slutföra på utsatt tid. Med tillgång till en kraftigare dator hade modellen sannolikt presterat något bättre, eftersom den hade kunnat tränas mer omfattande och utvärderas mot fler konfigurationer. Utmaningen ligger därmed i att hitta en lagom nivå givet den hårdvara som finns tillgänglig. Vår bedömning är att de flesta standarddatorer idag räcker gott och väl för att bygga en AI-baserad värderingsmodell av godtagbar kvalitet. Siktar man däremot på att ligga i den absoluta framkanten krävs kraftigare hårdvara, och i synnerhet tillgång till NVIDIAs grafikkort, vilket kan hantera träningen av AI-modeller snabbare än vad en processor klarar av. (Santopaolo 2025)

Sammanfattningsvis så är de största utmaningarna i skapandet av AI-baserade värderingsmodeller relaterade till data och variabelurval. När datakvaliteten är säkerställd, dataläckage-risker hanterade och variablerna informativa nog för att fånga både den lokala prisnivån och fastighetens egenskaper, blir den underliggande AI-modellen ett relativt rakt verktyg att applicera. Det är runt modellen, i datainsamling, kvalitetssäkring och variabelkonstruktionen, som det egentliga arbetet ligger.

7.3 Vilka är de etiska och samhällsmässiga begränsningarna med att använda AI-baserad fastighetsvärdering?

7.3.1 Sammanfattning

I denna diskussion analyseras aktuell forskning om AI- kontra mänsklig fastighetsvärdering. Empiriska studier visar att AI-baserade modeller ofta når hög effektivitet men varierande träffsäkerhet beroende på marknadsförhållanden. I stabila marknader kan erfarna värderare vara mer exakta, MdAPE cirka 3 % för människa och 5,4 % för AVM. Medan under mer dynamiska marknadsperioder kommer skillnaderna att minska (Birkeland m. fl. 2021). I vårt fall var MdAPE 13 % över hela landet spritt över flera olika marknadsperioder, både dynamiska och stabila. Dessa skillnader kan bero på storleken i datasetet som används då vi använde över 600 000 unika objekt i vårt dataset medan ingen av de andra nämnda studierna i arbetet hade över 100 000 unika objekt. I varje fall är det konstaterat av flera studier att mänskliga värderare kollektivt präglas av betydande inkonsekvens. Detta avser inte bara subjektiva mått som till exempel skick och design men även objektiva mått, exempelvis boyta vilket leder till stora skillnader mellan olika värderingsmän (Eriksen m. fl. 2020a, s. 22). Värderingsmän har dessutom tendenser att agera på contract price confirmation bias när de känner till ett avtalat pris. Därav tenderar de att justera sina bedömningar så att slutvärderingen bättre stämmer överens med köpeskillingen (Eriksen

m. fl. 2020a, s. 19). AI-modeller å andra sidan saknar medvetna fördomar och förutfattade meningar om köpeskillningar, men de är begränsade av träningsdatan och bär därför med sig risken att reproducera historiska mönster som återfinns i träningsdatan (Jonker och Rogers 2024). De skapar ofta spegelvariabler som indirekt kodar in känsliga attribut som till exempel postnummer som kopplar till socioekonomi (Alexandrov, Goodman och Neal 2023, s. 11). Mänskliga värderare ofta undervärderar fastigheter i områden med majoritet svart eller latino befolkning med 0,7-0,9 procentenheter jämfört med vita områden, medan AVM-modeller i genomsnitt inte visar någon explicit rasbaserad skillnad (Alexandrov, Goodman och Neal 2023), men har större felvariation i utsatta områden.

Överföringseffekter och systemrisker är också utmaningar som AI-baserad fastighetsvärdering möter. Homogenisering av modeller kan leda till synkroniserade prisbubblor (Teikari m. fl. 2025, s. 23). AI-genererade värderingar kommer i sin tur så småningom ligga till grunden för ny träningsdata vilket riskerar att skapa självförstärkande feedback-loopar där felaktiga värden cementeras och rörelser i prisgrafen förstärks (Teikari m. fl. 2025).

Införandet av AI-baserad värdering medför också försvårande ansvarsskyldighet och transparens. Komplexa black box-modeller är svåra att både granska och revidera vilket försvårar kunders förtroende och påverkar rättssäkerheten. Ytterligare etiska utmaningar inkluderar integritet. Tekniken som används riskerar att skapa detaljerade register över människors privatliv vilket skapar ett behov för tekniken att kunna hantera och filtrera bort känslig information. Arbetsmarknadsmässigt förväntas värderingsyrket polariseras och förändras. Hög kvalificerade analytiker och värderingsspecialister förblir svåra att ersätta, medan rutinarbeten junior roller riskerar att urholkas och ersättas automatiserade metoder och program (Teikari m. fl. 2025, s. 30). Likaså pressas mellanskiktet av värderare mellan dessa två yrkessegment. Det bör samtidigt understrykas att evidensen för de mer långtgående system- och arbetsmarknadsriskerna ovan, så som de beskrivs i tidigare forskning (framförallt (Teikari m. fl. 2025)), i hög grad är teoretisk och inte tidigare prövats mot ett praktiskt modellexperiment av det slag som genomförts i detta arbete. Våra egna erfarenheter, som utvecklas i avsnitt 7.3.3 och 7.3.6, pekar snarare på att de praktiska svårigheter som identifierats i avsnitt 7.2 — datakvalitet, hantering av icke-marknadsmässiga transaktioner, geografisk heterogenitet och det kontinuerliga behovet av mänsklig bedömning — utgör reella hinder som sannolikt begränsar både takten och formen på dessa förändringar. Modellhomogenisering och en polarisering av värderingsyrket bör därför inte betraktas som direkta och nära förestående konsekvenser av AI-baserad värdering, utan snarare som scenarier vars realisering förutsätter att hinder av det slag vi mött i praktiken först överbryggas.

7.3.2 Algoritmisk rättvisa och reproduktion av strukturell diskriminering

En av de principiellt mest betydelsefulla av de etiska utmaningarna AI-baserad fastighetsvärdering möter rör frågan om algoritmisk rättvisa. Till skillnad från mänskliga värderare kommer en AI-baserad fastighetsvärderingsmetod inte be-

sitta några medvetna fördomar i traditionell mening. Detta betyder dock inte att de är helt neutrala eller objektiva i sina bedömningar och utfall. Tvärtom bär maskininlärningsmodeller med sig en inneboende risk att reproducera och i vissa fall förstärka de strukturella ojämlikheter som återfinns i det historiska datamaterial på vilket de tränats. Problematiken rörande algoritmisk rättvisa är inte strikt unik för fastighetsvärdering men den får särskilt allvarliga konsekvenser i denna kontext då värderingsutfall direkt påverkar en enskilds ekonomiska förutsättningar. Detta genom tillgång till kapital och långsiktig förmögenhetsuppbyggnad. Problemet är väl dokumenterat i alla fall i amerikansk kontext. Historisk värderingsdata präglas av decennier av institutionell diskriminering, bland annat genom att ha använts av *redlining* där banker och myndigheter systematiskt uteslöt afroamerikanska och latinoamerikanska bostadsområden från bolån och investeringar. Om en AI-modell i sin tur tränas på sådan data lär den sig implicit att fastigheterna i dessa områden ”bör” värderas lägre. Detta inte på grund av objektiva egenskaper hos objekten utan på grund av socialt konstruerade och juridiskt sanktionerade värdemönster som präglat marknaden historiskt. (Teikari m. fl. 2025, s. 19). Problemet förvärras dessutom av att dessa diskriminerande mönster inte kodas in explicit i modellen. Variabler som ras eller etnicitet inkluderas normalt inte som direkta input variabler, men modellerna tenderar ändå att skapa så kallade proxyvariabler som indirekt kodar in samma information. Rent praktiskt hade detta kunnat vara till exempel att modellen lär sig att postnummer fungerar som en stark prediktor för socioekonomisk sammansättning och historisk diskriminering. När modellen i sin tur lär sig att postnummer X är förknippat med lägre priser finns risken att den istället för att utmana mönstret snarare befäster det istället då modellen tror att det är matematiskt korrekt (Teikari m. fl. 2025, s. 19).

Problem rörande algoritmisk rättvisa inte enbart är ett AI-baserat problem. Mänskliga värderare visar likaså de upp tydliga tendenser på diskriminerande värdering trots att dessa inte är helt begränsade till de algoritmer som behandlar träningsdata. Studier har visat att fastigheter i områden där majoritetsbefolkning utgörs av svart eller latinoamerikaner konsekvent undervärderas med 0,7-0,9 procentenheter jämfört med liknande fastigheter i områden med vit majoritetsbefolkning. I absoluta belopp innebär detta att det finns ett värderingsglapp mellan fastigheter i vita och svarta områden på cirka 156 miljarder dollar (Perry, Rothwell och Harshbarger 2018). Ur detta perspektiv kan en väl utformad AI-modell potentiellt reducera den individuella och yrkesmässiga bias som präglar mänskliga värderare. AVM-modeller uppvisar i genomsnitt inte någon explicit rasbaserad skillnad i sina medianvärderingar. De tenderar dock att ha avsevärt större felvarians i socioekonomiskt utsatta områden, vilket i sig är ett uttryck för en lägre modellkvalitet i dessa geografiska zoner och därmed ett mer osäkert underlag för ekonomiska beslut (Teikari m. fl. 2025). Ur ett rättviseperspektiv är detta inte ett neutralt utfall. En modell som konsekvent är mer osäker i vissa områden riskerar att systematiskt missgynna de grupper som redan befinner sig i en utsatt position på bostadsmarknaden.

Försök till att teknisk korrigera för algoritmisk diskriminering är metodologiskt

komplext och för med sig risken att normativa konflikter uppstår. Ett sätt att korrigera för algoritmiskt orättvisa är genom att konstruera AI-modellen på ett sådant sätt att den viktar vissa fastigheter på olika sätt än andra för att uppnå ett likvärdigt utfall. Problemet som uppstår är tvåfaldigt. Först och främst finns risken att fastigheter som inte behöver viktas, viktas och tvärtom. Likaså kan åtgärderna som behövs tas för att vikta fastigheter i dessa områden vara olika från område till område vilket betyder att det sannolikt inte finns ett schablonartat sätt att vikta samtliga fastigheter korrekt. Detta kan resultera i att AI-modellen gradvis urholkas genom ett stort antal ad hoc-baserade villkorsjusteringar, vilket riskerar att försämra modellens interna konsistens och därmed generera inkonsekventa värderingsutfall. Den andra typen av problem som uppstår rör rättvisepprinciper. Vill man sträva efter gruppbaserad rättvisa, det vill säga att utfallen i genomsnitt ska vara likvärdiga mellan olika grupper, så är korrigering av modellen genom viktning ett sätt att uppnå det. Dock står det i direkt konflikt med individbaserad rättvisa, det vill säga att varje enskild fastighet ska bedömas utifrån sina egna meriter (Teikari m. fl. 2025, s. 20). Med andra ord finns det inget tekniskt neutralt sätt att lösa dessa normativa spänningar. Varje designval i modellen innebär ett ställningstagande, och dessa ställningstaganden bör enligt flera forskare inte lämnas till algoritmdesigners ensamma, utan kräver bredare demokratisk och juridisk förankring.

Mycket av det som nämns i detta kapitel bygger på empirisk forskning från den amerikanska marknaden, trots detta bedöms det som relevant att reflektera kring hur dessa utmaningar manifesterar sig i en svensk kontext. Sverige skiljer sig från USA i flera avseenden som är direkt applicerbara för AI-baserad fastighetsvärdering. I Sverige är fastighetsmarknaden relativt väldokumenterad och digitaliserad sett till ett internationellt perspektiv. Det finns bland annat ett heltäckande fastighetsregister administrerat av Lantmäteriet, standardiserade energideklarationer och en relativt hög grad av transparens i köpeskillingsstatistik. I teorin skapar dessa faktorer goda förutsättningar för datadrivna värderingsmodeller eftersom tillgången på strukturerade och tillförlitliga data är en av viktigaste, om inte den viktigaste, förutsättningen för hög modellkvalitet. Movtons MdAPE på 13 % spritt över ett nationellt dataset med över 600 000 unika objekt illustrerar dock att även under gynnsamma dataförhållanden kvarstår betydande utmaningar i modelleringen. Även om det inte är fastslaget om detta beror på begränsad tid och resurser från vårt håll, bristande teknisk implementation från vårt håll eller till följd av den stora geografiska och marknadsmässiga heterogeniteten inom landet. Vad gäller algoritmisk diskriminering har Sverige inte samma historia, präglad av strukturell och formaliserad bostadssegregation, som USA. Svenska fastighetsdata saknar dock inte helt historiska ojämlikheter. Det finns en väldokumenterad socioekonomisk segregation i svenska städer och det är rimligt att anta att denna segregation återspeglas i prisnivåer på ett sätt som en naivt tränad modell riskerar att reproducera. Detta betyder att en modell tränad på svenska transaktionsdata kan komma att, utan explicit hänsyn till dessa mönster, befästa prisskillnader som speglar historiska strukturer istället för objektiva fastighetsvärden. Det går dock att argumentera för att det är normalt att området fastigheten är belägen i är en viktig aspekt för vad en po-

tentiell köpare är villig att betala för fastigheten. Utmaningen ligger snarare i detta fallet mer i att modeller uteslutande blickar bakåt och därmed riskerar att missa dynamiska skiften i stadsbilden exempelvis vid omfattande stadsförnyelse eller gentrifiering. Om modellen därför utgörs av träningsdata djupt rotad av en historiskt betingad bild av ett områdes socioekonomiska status kan algoritmen skapa en självuppfyllande profetia där sämre områden undervärderas trots faktiska förbättringar. Därav kan den svenska modellen även om den inte präglas av USAs historiska problem lida av systematisk eftersläpning som konserverar gårdagens segregationsmönster snarare än att spegla situationen idag

Regulatoriskt sett befinner sig Sverige, med Europeiska Unionen i spetsen, i ett skede av normbildning kring AI-användning. EU:s AI-förordning, EU artificial intelligence act, som trädde i kraft 2024 och vars bestämmelser successivt blir tillämpliga under de kommande åren klassificerar system som används för kreditbedömning och värdering av tillgångar som potentiellt högrisktillämpningar. Detta kommer innebära krav på transparens, dokumentation och mänsklig tillsyn (Europeiska unionen 2024). Regulatoriska ramverket skapar både möjligheter och utmaningar för aktörer som önskar implementera AI-baserade värderingsverktyg. Möjligheterna ligger i att detta ramverk kan komma att tvinga fram en ansvarsfull och transparent implementering än vad en oreglerad marknad förmodligen hade genererat. Utmaningarna ligger å andra sidan i att uppfylla kraven som ställs på förklarbarhet och dokumentation, särskilt när det i många fall handlar om modeller vars prediktiva styrka delvis är en funktion av deras komplexitet.

7.3.3 Systemrisk, modellhomogenisering och finansiell stabilitet

Utöver etiska utmaningar kopplade till enskilda fastigheter och individer som präglar AI-baserad fastighetsvärdering finns även frågor på systemnivå. Tidigare forskning beskriver hur flera marknadsaktörer som använder samma eller strukturellt liknande modeller, tränade på överlappande data, riskerar att producera synkroniserade under- och övervärderingar. Detta hade kunnat vara ett potentiellt hot mot den finansiella stabiliteten med paralleller till algoritmbaserad handel (Teikari m. fl. 2025, s. 23). Till detta kommer risken för algoritmiska återkopplingsloopar, där AI-genererade värderingar i sin tur blir framtida träningsdata och därmed riskerar att förstärka och cementera eventuella systematiska fel (Teikari m. fl. 2025, s. 23).

Det är dock värt att ställa denna risk i relation till de erfarenheter som gjorts inom ramen för det egna modellexperimentet. Movton är byggd på en datakälla, som är väldigt lik den data andra Svenska värderingsaktörer använder sig av. I den meningen är förutsättningarna för homogenisering goda. Trots detta krävde den färdiga modellen ett stort antal modelleringsval som inte följer direkt ur datan, utan utgör resultatet av eget omdöme: var gränserna för K/T-kvoten sattes (avsnitt 5.16.1), vilka observationer som klassades som outliers (avsnitt 5.9.3), var brytpunkten för lyxmodellen lades och hur övergången mellan grund- och lyxmodell utformades (avsnitt 5.20.5), samt vilka variabler som togs bort

vid kollinearitetsanalysen (avsnitt 5.19.3). Att två team med tillgång till samma råa transaktionsdata skulle göra identiska val i samtliga dessa avseenden framstår som mindre sannolikt. Modellhomogenisering i en stark mening, att flera oberoende aktörer av sig själva konvergerar mot praktiskt taget samma modell, förutsätter alltså inte bara delad rådata, utan även en konvergens i ett stort antal sådana normativa och tekniska delval, vilket vårt arbete tyder på är ett icke-trivialt steg.

Resultaten ger också anledning att problematisera föreställningen att mer data i sig leder till bättre eller mer konvergerande modeller. Trots att Movton tränats på över 600 000 transaktioner vilket är väsentligt fler än de studier som ofta citeras i detta sammanhang så uppvisar modellen ett MdAPE på 13 % som är klart högre än till exempel (Birkeland m. fl. 2021, s. 4) som var 5,4 % och (Björgve m. fl. 2025, s. 640) respektive 5,24 %. Som diskuterats i avsnitt 7.2 är den mest rimliga förklaringen den geografiska och marknadsmässiga heterogeniteten i ett nationellt dataset, inte bristande datavolym. Det talar för att aktörer som prioriterar precision snarare har incitament att bygga regionalt eller segmentmässigt specialiserade modeller, vilket vår egen lyxmodell är ett exempel på, än att konvergera mot en gemensam nationell modell. I så fall skulle ökad AI-användning på sikt kunna leda till ett mer differentierat snarare än mer homogent AVM-landskap, åtminstone bland aktörer för vilka precision är affärskritisk.

Detta innebär inte att risken för modellhomogenisering kan avskrivas. Den framstår dock, baserat på våra erfarenheter, mindre som en spontan eller oundviklig konsekvens av att fler aktörer börjar använda AI, och mer som en fråga om marknadsstruktur på infrastruktur- och dataleverantörssidan. Om ett litet antal dataleverantörer eller mjukvaruplattformar (jämför Värderingsdata, Booli) i praktiken kommer att utgöra den gemensamma grunden för de flesta svenska AVM:er, ökar risken för konvergens oavsett hur mycket bespoke arbete varje enskild aktör i övrigt lägger ner. Det är sannolikt också där eventuell tillsyn och reglering har störst möjlighet att påverka utfallet, snarare än genom att rikta in sig på den enskilda modellarkitekturen.

7.3.4 Transparens, ansvarsskyldighet och rättssäkerhet

En annan etisk dimension rör frågan om transparens och ansvarsskyldighet. Moderna maskinlärningsmodeller, särskilt djuplärningsbaserade arkitekturer och avancerade ensemble-metoder som XGBoost och stacked generalization, är till sin natur svåra att tolka. Samtliga AI-modeller producerar prediktioner som är svåra att härleda från specifika inputvariabler och därmed blir det väldigt svårt att veta varför en AI värderar som den gör. Kortfattat så skickar en användare ett input till en AI och den svarar med en prediktion, utan någon som helst förklaring till hur den kom till svaret. Problemet brukar betecknas som black box-problematiken (Teikari m. fl. 2025, s. 16). Denna ogenomskinlighet är inte enbart ett tekniskt problem utan även ett juridiskt och etiskt sådant. I en traditionell fastighetsvärdering är värderaren en namngiven yrkesperson som bär ett personligt yrkesansvar för sina bedömningar. Det finns etablerade mekanismer

för överklagande, granskning och skadeståndsskyldighet om en värdering visar sig vara felaktig och leder till ekonomisk skada för köpare eller säljare. Allt detta bygger på att det går att utkräva ansvar av en identifierbar aktör som kan redogöra för sin metodik samt motivera sin slutsats. När en algoritm bidrar till eller i sin helhet fattar värderingsbeslutet, försvåras dessa traditionella ansvars-mekanismer avsevärt. Det är i sådana situationer oklart om ansvaret ska bäras av den organisation som drifrar modellen, de ingenjörer som designade den, de aktörer som samlade in träningsdatan, eller den certifierade värderare som signerade den slutgiltiga rapporten utan att ha genomfört en egentlig självständig analys (Teikari m. fl. 2025, s. 16). Otydligheten i ansvarskedjan är inte enbart ett juridiskt och tekniskt problem utan det påverkar även i grunden möjligheterna för rättssäker hantering av fastighetstransaktioner. Fastighetsköp är för de flesta privatpersoner den enskilt största ekonomiska transaktion de genomför under sin livstid. Vid en systematisk felvärdering, oavsett hur uppenbar eller subtil, kan få konsekvenser som sträcker sig decennier framåt i form av felaktigt belåningsutrymme, felaktiga försäkringsunderlag och förluster vid framtida försäljning. I ett sådant sammanhang är transparens inte enbart att föredra utan ett grundläggande krav för att systemet ska vara legitimt och rättssäkert.

Forskning inom området har gjort avsevärda framsteg under senare, specifikt gällande XAI. Det finns idag metoder som SHAP-värden som i viss mån möjliggör att i efterhand analysera vilka variabler som bidragit mest till en enskild modells prediktion. Det kan därmed ge en partiell förklaring av utfallet även för annars ogenomskinliga modeller. Metoder som SHAP-värden är dock inte helt utan begränsningar. De ger enbart en förklaring på variabelnivå, hur mycket varje variabel påverkar en prediktion snarare än att förklara varför variabeln påverkar. De kan även vara känsliga för hur inputdata är kodad. Inte heller skapar SHAP-värden nödvändigtvis en bild av den underliggande modellarkitekturen som är tillräckligt detaljerad för att möta juridiska krav på redovisningsskyldighet. Transparens i AI-baserad fastighetsvärdering kräver därav en bred institutionell insats som sträcker sig bortom den rent tekniska domänen och inkluderar tydliga juridiska ramverk för ansvarsskyldighet, revisionsmekanismer och möjligheter till överklagande.

7.3.5 Integritet och datainsamling i en digitaliserad värderingsprocess

I takt med att fastighetsvärdering i allt större utsträckning förlitar sig på avancerade datainsamlingstekniker uppstår parallellt en rad frågor om personlig integritet. Traditionell fastighetsvärdering har visserligen alltid inneburit ett visst intrång i den privata sfären i form av besiktningsbesök. Omfattningen och hur permanent datamaterialet är har dock historiskt varit begränsat. Modern AI-driven datainsamling har förändrat denna situation i grunden. När AI-baserad fastighetsvärdering inte längre begränsas till behandling av existerande uppgifter, utan även innefattar systematisk insamling av ny data, kommer nya problem kopplade till integritet att skapas. Tekniker som drönare utrustade med högupplösta kameror och LiDAR-sensorer, 3D-inomhusscanning och automatisk bildanalys möjliggör en datainsamling av avsevärt större detaljgrad än tidigare.

En 3D-scanning av en privatbostad skapar ett underlag för ytberäkningar och rumslighetsbedömningar men som effekt av detta skapas även ett permanent, detaljerat digitalt avtryck av bostaden vid en specifik tidpunkt. I detta material kan personliga dokument vara synliga, barnrum och personliga ägodelar kan kartläggas och livsstilsmönster kan indirekt avläsas av hur utrymmen används och möbleras (Teikari m. fl. 2025, s. 10). Materialet i frågan är av fundamentalt annan karaktär än den som traditionellt ingår i en fastighets värderingsunderlag men kommer att vara nödvändigt om AI-baserad värdering utvecklas till en helt automatiserad process där datainsamling, analys och värdebedömning integreras i ett sammanhängande system.

Det är inte uppenbart att de lagliga och etiska ramar som reglerar fastighetsvärdering är utformade för att hantera dessa nya datakategorier. Även i en europeisk kontext, där GDPR är det primära juridiska ramverket för hantering av persondata, är det emellertid inte självklart hur GDPR ska tillämpas på 3D-modeller av privatbostäder eller bildanalys som automatiskt identifierar och klassificerar innehållet i ett hem. Huruvida sådant material ska betraktas som personuppgifter i GDPR:s mening, vem som är personuppgiftsansvarig och hur länge materialet får lagras är frågor som i dagsläget saknar entydiga juridiska svar. Det finns ett tydligt behov av tekniska lösningar som automatiskt filtrerar bort känslig information från det material som lagras och används för modellträning. Utöver behovet för tekniska lösningar finns det ett behov av ett normativt och juridiskt klagörande av vad som faktiskt räknas som känslig information i detta sammanhang (Teikari m. fl. 2025, s. 10). Viktigt att notera är att integritetsfrågan inte är begränsad till enskilda fastighetsbesiktningar. Det handlar om aggregerad datainsamling som sker när stora volymer av värderingsdata samlas in och centraliseras. Det skapar i sin tur nya integritetsrisker. Mönster i bostadsdata kan användas för att dra slutsatser om individers beteenden, ekonomi och livssituation. Sådana slutsatser kan potentiellt komma att användas i sammanhang som den enskilde inte förutsett eller godkänt vid tidpunkten för värderingen. Därav kommer AI-baserad fastighetsvärdering att behöva ändra hanteringen av fastighetsvärderingsdata till systemperspektiv som sträcker sig bortom den enskilda transaktionen.

7.3.6 Arbetsmarknad, yrkesroller och social omställning

Forskning pekar på att värderingsyrket sannolikt kommer att polariseras. Ett övre segment av högkvalificerade specialister som hanterar komplexa och atypiska fall förblir svårt att automatisera, medan ett nedre segment av lågkvalificerade datainsamlare kan växa fram. Mellanskiktet, de värderare som idag utför störst andel av branschens standardiserade rutinvärderingar, beskrivs som det segment som utsätts för det starkaste automatiseringstrycket (Teikari m. fl. 2025, s. 28, 30)

Erfarenheterna från modellexperimentet ger dock anledning att granska var gränsen mellan "rutinmässigt" och "icke-rutinmässigt" arbete egentligen bör dras i denna beskrivning. En stor del av det arbete som krävdes för att bygga Mov-

ton skulle vid första anblick klassas som ren databehandling, men visade sig i praktiken kräva fastighetsspecifik bedömning. Identifieringen av automatiskt genererade sammanfattningsrader, hanteringen av semikolonseparerade värden för fastigheter med flera byggnader (avsnitt 5.9), och inte minst upptäckten av icke-marknadsmässiga transaktioner, gjordes inte av modellen eller av ett automatiserat filter, utan genom att vi som utvecklare visuellt granskade KNN-grannarna i gränssnittet och noterade att en granne sålts för cirka 1 000 000 kr medan övriga objekt i området låg kring 5–6 miljoner kronor (avsnitt 5.16). Att sätta gränsvärden för K/T-kvoten, definiera vad som utgör ”lyxsegmentet” eller avgöra vilka variabler som är redundanta vid kollinearitet (avsnitt 5.19.3) är på samma sätt uppgifter som kräver insikt i hur den svenska fastighetsmarknaden fungerar, inte bara teknisk förmåga.

Detta mönster återkommer i utvärderingen. De avvikelser som identifierades i stickproven (avsnitt 6.7) var konsekvent kopplade till objektspecifik information som modellen saknade tillgång till: ett konstaterat radonhus (B5), en taxerad standardpoäng som inte speglade fastighetens faktiska, moderna skick (B10), eller en avvikande energiklassificering som visade sig bero på en sannolik felregistrering (B8). Det är precis denna typ av lokal- och objektkännedom, att känna igen att ett pris eller en uppgift ”ser fel ut” och förstå varför, som i litteraturen tillskrivs mellanskiktets yrkeskompetens, snarare än lågkvalificerad datainsamling.

Sammantaget tyder detta på att ”rutinmässighet” inom fastighetsvärdering inte primärt är en funktion av hur repetitivt arbetet är, utan av hur fullständig och tillförlitlig den underliggande informationen är. Så länge data om skick, planlösning och objektspecifika avvikelser är bristfälliga vilket vårt arbete visar är regeln snarare än undantaget. Även med tillgång till en av Sveriges mer kompletta datakällor kommer en betydande del av det som idag kallas rutinvärdering att bestå av just det arbete som mellanskiktet utför. Alltså att upptäcka, tolka och korrigera för dessa luckor. Det mest sannolika kortsiktiga utfallet är därför inte att mellanskiktet eroderas bort, utan en uppgiftsförskjutning inom samma yrkesgrupp, från att producera värderingar från grunden till att granska, komplettera och korrigera AI-genererade baseline-värderingar, i linje med den hybridmodell som beskrivs i avsnitt 3.2. Detta innebär inte att inga arbetsmarknadseffekter uppstår. Snarare att den totala arbetsvolymen per transaktion kan mycket väl minska över tid. Men eftersom en sådan minskning förutsätter just den typ av detaljerade datakvalitetsförbättringar som mellanskiktet idag bidrar med, framstår en snabb eller abrupt polarisering som mindre trolig än en gradvis omdefiniering av yrkesrollen.

8 Slutsats

AI-baserade värderingsmodeller fungerar genom att identifiera och kvantifiera statistiska samband mellan fastighetsattribut och historiska transaktionspriser via maskininlärning. I detta arbete har XGBoost i kombination med SHAP-värden visat sig vara ett ändamålsenligt verktyg då det erbjuder en bra kombination mellan både prediktiv förmåga och förklarbarhet. Utvecklade modellen uppnådde ett MdAPE på 13 % och ett r^2 -värde på 0,871 på ett nationellt dataset om över 600 000 försäljningar, vilket får anses vara ett godtagbart resultat givet arbetets resursmässiga begränsningar och den geografiska och tidsmässiga bredden i datasetet. Hybridmodeller, där AI-baserade verktyg kombineras med mänsklig expertis, framstår som det mest realistiska och robusta sättet att implementera AI inom fastighetsvärdering i närtid. En renodlad AI-modell saknar den kontextuella förståelse och det professionella omdöme som krävs i komplexa värderingssituationer, medan en hybridlösning möjliggör att styrkorna hos båda tillvägagångssätten tas tillvara.

De största utmaningarna i skapandet av AI-baserade värderingsmodeller har visat sig ligga utanför själva algoritmvalet. De rör i första hand datakvalitet, hantering av icke-marknadsmässiga transaktioner, skydd mot dataläckage vid konstruktionen av lokala prisankare samt tillgången till variabler som beskriver fastighetens faktiska skick. Därtill kommer modellens geografiska bredd, där en nationell modell får en högre felmarginal än en regionalt avgränsad, samt de resursmässiga ramarna inom vilka ett arbete av detta slag bedrivs. När dessa förutsättningar väl är hanterade blir den underliggande AI-modellen ett relativt rakt verktyg att applicera, och det egentliga arbetet ligger i datainsamlingen, valideringen och feature-konstruktionen runt modellen.’

Dessa praktiska utmaningar har en direkt koppling till de mer långtgående risker som diskuteras i avsnitt 7.3.3 och 7.3.6. Om datakvalitet, hantering av icke-marknadsmässiga transaktioner och geografisk heterogenitet utgör betydande hinder redan inom ramen för detta arbete, är det rimligt att anta att motsvarande hinder gäller, i varierande grad, för andra aktörer som bygger liknande modeller. Detta talar emot att en snabb modellhomogenisering eller en abrupt polarisering av värderingsyrket är de mest sannolika kortsiktiga konsekvenserna av AI-baserad fastighetsvärdering, och pekar snarare mot en gradvis hybridisering där dessa hinder successivt, men inte omedelbart, hanteras.

Sammantaget är det tydligt att de etiska och samhällsmässiga utmaningar som AI-baserad fastighetsvärdering medför inte enbart kan reduceras till isolerade tekniska problem med lika isolerade tekniska lösningar. Det berör istället mer fundamentala frågor om rättvisa, ansvarsskyldighet och samhälls- och hushållsekonomin. Interdisciplinärt angreppssätt som inkluderar juridiska, ekonomiska och sociologiska perspektiv vid sidan av det rent tekniska. Att en modell enbart är effektiv i statistisk mening är inte tillräckligt för att den ska vara legitim i en etisk mening. En högt presterande modell som reproducerar strukturell diskriminering, som undergräver finansiell stabilitet, som är ogenomskinlig för dem

vars ekonomiska liv den påverkar, eller som koncentrerar fördelarna hos kapitalstarka aktörer på bekostnad av lönearbetare, är inte ett fullgott substitut för en väl fungerande och rättvist reglerad mänsklig värderingsprocess. Det betyder inte att AI-baserade verktyg helt saknar en plats i fastighetsvärderingsbranschen. Emellertid tyder evidensen snarare på att AI-modeller och i synnerlighet hybridmodeller kan erbjuda verkliga förbättringar i både precision och kostnadseffektivitet, men det under rätt förutsättningar. Förutsättningar som inte är tekniska till sin natur utan snarare är de institutionella, juridiska och etiska, och de kräver en lika stor investering i normativa ramverk som i algoritmisk kapacitet.

9 Källor

- Alexandrov, Alexei, Laurie Goodman och Michael Neal (2023). *Reengineering the Appraisal Process*. Urban Institute, Housing Finance Policy Center. URL: <https://www.urban.org/sites/default/files/2023-01/Reengineering%20the%20Appraisal%20Process.pdf> (Hämtad 2026-03-18).
- Almaas, Vebjørn, Are Oust och Arne Johan Pollestad (jan. 2025). *Giving Eyes to Automated Valuation Models: Computer Vision Assessment of Interior Home Condition*. DOI: 10.2139/ssrn.5742685.
- Arrieta, Alejandro Barredo m.fl. (2019). "Explainable Artificial Intelligence (XAI): Concepts, Taxonomies, Opportunities and Challenges toward Responsible AI". I: *arXiv preprint arXiv:1910.10045*. arXiv: 1910.10045 [cs.AI]. URL: <https://arxiv.org/abs/1910.10045>.
- Bengtsson, Ingemar (2023). *Fastighetsvärdering: om värdeteori och värderingsmetoder*. 2. utg. Lund: Studentlitteratur AB. ISBN: 9789144176918.
- Birkeland, Kristoffer B. m.fl. (2021). "The Predictability of House Prices: "Human Against Machine"". I: *International Real Estate Review* 24.2, s. 139–183.
- Björgve, Elias m.fl. (29 sept. 2025). "Comparing Housing Valuation Techniques and Stacked Generalization: Exploiting Explainable AI". I: Received: 2023-09-18; Accepted: 2025-08-18.
- Bommasani, Rishi m.fl. (2021). *On the Opportunities and Risks of Foundation Models*. Tekn. rapport. Updated 2022. Stanford Institute for Human-Centered AI (HAI), s. 11. URL: <https://arxiv.org/abs/2108.07258> (Hämtad 2024-05-22).
- Brynjolfsson, Erik, Danielle Li och Lindsey R. Raymond (2023). *Generative AI at Work*. Working Paper 31161. National Bureau of Economic Research. DOI: 10.3386/w31161. URL: <https://www.nber.org/papers/w31161> (Hämtad 2024-05-22).
- Burrell, Jenna (2016). "How the machine 'thinks': Understanding opacity in machine learning algorithms". I: *Big Data & Society* 3.1, s. 1–12. DOI: 10.1177/2053951715622512. URL: <https://journals.sagepub.com/doi/full/10.1177/2053951715622512>.
- Chen, Tianqi och Carlos Guestrin (2016). "XGBoost: A Scalable Tree Boosting System". I: *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. KDD '16. New York, NY, USA: Association for Computing Machinery, s. 785–794. ISBN: 9781450342322. DOI:

10.1145/2939672.2939785. URL: <https://dl.acm.org/doi/10.1145/2939672.2939785>.

Dwivedi, Yogesh K. m. fl. (2023). "So what if ChatGPT wrote it? Multidisciplinary perspectives on opportunities, challenges and implications of generative conversational AI for research, practice and policy". I: *International Journal of Information Management* 71, s. 46. DOI: 10.1016/j.ijinfomgt.2023.102642. URL: <https://doi.org/10.1016/j.ijinfomgt.2023.102642> (Hämtad 2024-05-22). Se avsnitt 4.4.6.1.

Erciyes, Ahmet Hilmi m. fl. (2025). "Learning the Value of Place: Machine Learning Models for Real Estate Appraisal in Istanbul's Diverse Urban Landscape". I: *Buildings* 15.15. ISSN: 2075-5309. DOI: 10.3390/buildings15152773. URL: <https://www.mdpi.com/2075-5309/15/15/2773>.

Eriksen, Michael D. m. fl. (febr. 2020a). "Contract Price Confirmation Bias: Evidence from Repeat Appraisals". I: *The Journal of Real Estate Finance and Economics* 60.1, s. 77–98.

– (febr. 2020b). "The Influence of Contract Prices and Relationships on Collateral Valuation". I: *The Journal of Real Estate Finance and Economics* 60.1. Affiliations: Michael D. Eriksen (University of Cincinnati), Hamilton B. Fout (Fannie Mae and Kansas State University), Mark Palim (Fannie Mae), Eric Rosenblatt (Fannie Mae), s. 77–98.

Europeiska unionen (2024). *Europaparlamentets och rådets förordning (EU) 2024/1689 av den 13 juni 2024 om fastställande av harmoniserade regler för artificiell intelligens (förordning om artificiell intelligens)*. URL: <http://data.europa.eu/eli/reg/2024/1689/oj> (Hämtad 2024-05-22).

Finansinspektionen (2024). *Den svenska bolånemarknaden*. Stockholm: Finansinspektionen. URL: <https://www.finansinspektionen.se/contentassets/324ca6f343e64a088c62e075b0edb8ef/den-svenska-bolanemarknaden.pdf> (Hämtad 2026-03-16).

Freeman III, A. Myrick, Joseph A. Herriges och Catherine L. Kling (2014). *The Measurement of Environmental and Resource Values: Theory and Methods*. 3. utg. New York: Routledge. ISBN: 978-0415501583.

Grand View Research (2025). *Smart Home Market Size, Share and Trends Analysis Report By Product, By Protocols, By Application, By Region, And Segment Forecasts, 2025–2030*. URL: <https://www.grandviewresearch.com/industry-analysis/smart-homes-industry> (Hämtad 2026-02-10).

He, Sheng och Yongliang Chen (2025). "A high-performance extreme gradient boosting outlier detection framework for integrating the outputs of diverse

- anomaly detectors for detecting mineralization-related geochemical anomalies”. I: *Journal of Geochemical Exploration* 273, s. 107741. ISSN: 0375-6742. DOI: <https://doi.org/10.1016/j.gexplo.2025.107741>. URL: <https://www.sciencedirect.com/science/article/pii/S0375674225000731>.
- Hooker, Sara (2020). *The Hardware Lottery*. arXiv: 2009.06489 [cs.LG]. URL: <https://arxiv.org/abs/2009.06489> (Hämtad 2024-05-22).
- Högsta domstolen (mål nr T 2838-20). *Högsta domstolens dom den 27 maj 2021 i mål nr T 2838-20*.
- International Valuation Standards Council (2021). *International Valuation Standards (IVS)*. Standard 105: Valuation Approaches and Methods. IVSC. London, UK. URL: <https://www.ivsc.org/standards/> (Hämtad 2024-05-22).
- Jonker, Alexandra och Julie Rogers (2024). *What is algorithmic bias?* Engelska. IBM Think. URL: <https://www.ibm.com/think/topics/algorithmic-bias> (Hämtad 2024-05-22).
- Jordan, Michael I. och Tom M. Mitchell (2015). "Machine learning: Trends, perspectives, and prospects". I: *Science* 349.6245, s. 255–260. DOI: 10.1126/science.aaa8415. URL: <https://www.science.org/doi/10.1126/science.aaa8415> (Hämtad 2024-05-22).
- Kante, L. (2024). *9 av 10 väljer digitalt lås*. Aktuell Säkerhet. URL: <https://www.aktuellsakerhet.se/9-av-10-valjer-digitalt-las/> (Hämtad 2026-02-10).
- Kee, Tris och Winky K. O. Ho (2025a). "eXplainable Machine Learning for Real Estate: XGBoost and Shapley Values in Price Prediction". I: *Civil Engineering Journal* 11.5, s. 2116–2133. DOI: 10.28991/CEJ-2025-011-05-022. URL: <https://civilejournal.org/index.php/cej/article/view/5811>.
- (maj 2025b). "eXplainable Machine Learning for Real Estate: XGBoost and Shapley Values in Price Prediction". Engelska. I: *Civil Engineering Journal* 11.05. ISSN (Print): 2676-6957. ISSN: 2476-3055.
- Kumkar, Prathamesh m. fl. (2018). "Comparison of Ensemble Methods for Real Estate Appraisal". I: *2018 International Conference on Inventive Computation Technologies (ICICT)*. Coimbatore, India: IEEE. ISBN: 978-1-5386-4985-5. DOI: 10.1109/ICICT.2018.8473324.
- Lind, Hans (2014). *Principles of Property Valuation*. Ingår i samlingsvolym för fastighetsekonomisk teori. Sektion om avkastningsvärdering och kassaflödesanalys. Stockholm, Sweden: KTH Royal Institute of Technology. URL: <https://>

[//www.kth.se/polopoly_fs/1.1014245.1601036195!/Hans%20Lind%2070%C3%A5r.pdf](http://www.kth.se/polopoly_fs/1.1014245.1601036195!/Hans%20Lind%2070%C3%A5r.pdf) (Hämtad 2024-05-22).

Lundberg, Scott M. och Su-In Lee (2017). "A Unified Approach to Interpreting Model Predictions". I: *Advances in Neural Information Processing Systems 30 (NeurIPS 2017)*. Utg. av I. Guyon m.fl. Curran Associates, Inc. URL: <https://papers.neurips.cc/paper/7062-a-unified-approach-to-interpreting-model-predictions>.

Nordlo (15 febr. 2024). *Framtidens digitala verktyg inom fastighetssektorn*. URL: <https://nordlo.com/kunskapspost/framtidens-digitala-verktyg-inom-fastighetssektorn> (Hämtad 2025-02-10).

Perry, Andre M., Jonathan Rothwell och David Harshbarger (nov. 2018). *The Devaluation of Assets in Black Neighborhoods: The Case of Residential Property*. Research Report. Metropolitan Policy Program. Washington, D.C.: Brookings Institution. URL: <https://www.brookings.edu/articles/devaluation-of-assets-in-black-neighborhoods/> (Hämtad 2026-04-22).

Poursaeed, Omid, Tomas Matera och Serge Belongie (maj 2018). "Vision-based Real Estate Price Estimation". I: *Machine Vision and Applications* 29. DOI: 10.1007/s00138-018-0922-2.

Qin, Yujia m.fl. (3 okt. 2023). *ToolLLM: Facilitating Large Language Models to Master 16000+ Real-world APIs*. Version 2; submitted 2023-07-31. arXiv: 2307.16789.

Raghavan, Deepti m.fl. (22 juli 2025). *Alto: Orchestrating Distributed Compound AI Systems with Nested Ancestry*. Version 3; submitted 2024-03-07.

Ribeiro, Marco Tulio, Sameer Singh och Carlos Guestrin (2016). "Why Should I Trust You? Explaining the Predictions of Any Classifier". I: *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, s. 1135–1144. DOI: 10.1145/2939672.2939778. URL: <https://dl.acm.org/doi/10.1145/2939672.2939778>.

Samek, Wojciech, Thomas Wiegand och Klaus-Robert Müller (2017). *Explainable Artificial Intelligence: Understanding, Visualizing and Interpreting Deep Learning Models*. arXiv preprint arXiv:1708.08296. URL: <https://arxiv.org/abs/1708.08296>.

Santopaolo, Gian Paolo (3 dec. 2025). *Why GPUs Love Tensors: Understanding Tensor Cores and AI Acceleration*. GenMind. URL: <https://genmind.ch/posts/Why-GPUs-Love-Tensors-Understanding-Tensor-Cores/> (Hämtad 2026-04-28).

- Sevilla, Jaime m.fl. (2022). "Compute Trends Across Three Eras of Machine Learning". I: *arXiv preprint*. arXiv: 2202.05924 [cs.LG]. URL: <https://arxiv.org/abs/2202.05924> (Hämtad 2024-05-22).
- Sinnott, Roger W. (1984). "Virtues of the Haversine". I: URL: <https://api.semanticscholar.org/CorpusID:166968314>.
- Statistikmyndigheten SCB (2024). *Distrikt*. Hämtad 2025-05-07. URL: <https://www.scb.se/hitta-statistik/regional-statistik-och-kartor/regionala-indelningar/distrikt/>.
- Svensk Byggtjänst (19 mars 2021). *60 procent har ökat sin användning av branschspecifika digitala verktyg*. Svensk Byggtjänst. URL: <https://svenskbyggtjanst.mynewsdesk.com/pressreleases/60-procent-har-oekat-sin-anvaendning-av-branschspecifika-digitala-verktyg-3083154> (Hämtad 2025-02-10).
- Teikari, Petteri m.fl. (6 aug. 2025). "The Architecture of Trust: A Framework for AI-Augmented Real Estate Valuation in the Era of Structured Data". Engelska. I: *Mill Hill Garage / JB Real Estate Valuation & Advisory*. Corresponding author: petteri@millhillgarage.com.
- Topraklı, Abdurrahman Yağmur (2024). "AI-driven valuation: a new era for real estate appraisal". I: *Journal of European Real Estate Research*. Received 30 April 2024; Revised 25 August 2024 and 28 October 2024; Accepted 3 November 2024. ISSN: 1753-9269. URL: <https://www.emerald.com/insight/1753-9269.htm>.
- Valier, Agostino (2020). "Who performs better? AVMs vs hedonic models". I: *Journal of Property Investment & Finance* 38.3, s. 213–225. ISSN: 1463-578X. DOI: 10.1108/JPIF-12-2019-0157.
- Wyman, David, Maury Seldin och Elaine Worzala (2011). "A new paradigm for real estate valuation?" I: *Journal of Property Investment & Finance* 29.4/5, s. 341–358. DOI: 10.1108/14635781111150341.