



# Energibesparande renoveringspotential

Renoveringspotentialen för det svenska  
flerbostadshusbeståndet uppskattad med maskininlärning

Kajsa Jörgensson  
Viktor Karlsson

Examensarbete på Civilingenjörsnivå  
Avdelningen för Energihushållning  
Institutionen för Energivetenskaper  
Lunds Tekniska Högskola | Lunds Universitet



# ENERGIBESPARANDE RENOVERINGSPOTENTIAL

RENOVERINGSPOTENTIALEN FÖR DET SVENSKA  
FLERBOSTADSHUSBESTÅNDET UPPSKATTAD  
MED MASKININLÄRNING

JANUARI 2020, LUND

## **Författare**

Kajsa Jörgensson  
Viktor Karlsson

## **Handledare**

Sara Månsson, Lunds Tekniska Högskola, Lunds Universitet  
Claes Sandels, RISE Research Institutes of Sweden

## **Examinator**

Marcus Thern, Lunds Tekniska Högskola, Lunds Universitet

Föreliggande examensarbete på civilingenjörsnivå har genomförts vid Avd. för Energihushållning, Inst för Energivetenskaper, Lunds Universitet - LTH samt vid Research Institutes of Sweden (RISE) i Göteborg. Handledare på RISE: Claes Sandels, forskare; handledare på LU-LTH: Sara Månsson, doktorand; examinator på LU-LTH: Marcus Thern, universitetslektor.

Examensarbete på Civilingenjörsnivå

ISRN LUTMDN/TMHP-20/5449-SE

ISSN 0282-1990

© 2020 Kajsa Jörgensson & Viktor Karlsson samt Energivetenskaper

Energihushållning

Institutionen för Energivetenskaper

Lunds Universitet - Lunds Tekniska Högskola

Box 118, 221 00 Lund

[www.energy.lth.se](http://www.energy.lth.se)

# Förord

Den primära forskarfrågeställningen och idén till projektet kommer ursprungligen från RISE och deras större forskningsprojekt *Artificiell intelligens för tolkning av renoveringsbehov* (projekt-nr 46797-1). Det större projektet ämnar att identifiera mönster i flerbostadshusbeståndet och med utgångspunkt från dessa göra mer specifika analyser av energieffektiviseringspotentialen för flerbostadshus i Sverige. RISE bidrar med analyser av energibesparingspotentialen samt kostnadsuppskattningar, som underlag till den nationella renoveringsstrategin [1]. Detta examensarbete ingår som en del i det större forskningsprojektet.

Detta är vår avslutande del av civilingenjösutbildningen Maskinteknik och vi vill tacka alla som på något sätt varit involverade i detta arbete. Era värdefulla tips, råd och uppmuntrande ord har varit guld värda.

Tack till Claes Sandels, maskininlärningsexperten, som med sin mångåriga erfarenhet av tillämpad maskininlärning, vilja att bidra med sin expertis och positiva inställning har gjort detta arbete möjligt. Vi har lärt oss extremt mycket inom området maskininlärning tack vare dig.

Vi vill tacka Sara Månsson, vårt bollplank i alla lägen, för att hon ständigt varit närvarande och funnits där för oss från start till slut. Med hennes öga för detaljer har hon under arbetets gång hjälpt oss öka kvaliteten på vårt arbete. Du har bidragit med professionella inputs, varvat med humor, vilket har gjort denna höst både rolig och lärorik.

Tack till Kristina Mjörnell, affärs- och innovationsområdeschef på RISE, som bidragit med nya idéer, erfarenhet och specifik domänkunskap. Ditt engagemang smittar av sig och vi är tacksamma för all vägledning du gett oss under projektet.

Vi vill också passa på att rikta ett tack till Jenny von Platten, doktorand på RISE, för värdefull support som endast varit ett telefonsamtal bort. Vi är tacksamma att vi kunnat ställa alla *dumma* frågor och att du ständigt bemött oss med extremt stor kunskap och förståelse.

Lund, Januari 2020

*Kajsa Jörgensson & Viktor Karlsson*

# Abstract

The Swedish apartment building stock from 1945-1975 is reaching the end of its technical life span. Renovations and energy efficiency measures are needed to reduce energy use and enable continued usage of the buildings in the future and still provide affordable housing to socioeconomic vulnerable groups. The problem today is that some building features, which are needed to estimate the renovation potential, are unknown. The policy makers in Sweden care about this problem due to the fact that every EU country has to submit a long-term renovation strategy that foster investments in the renovation of buildings. To make this renovation strategy realistic, more information such as specific building features, are needed. Patterns of the building stock can be found using sophisticated Machine Learning methods. These will contribute in developing a sustainable long-term renovation strategy for Sweden.

This study is made to investigate possible solutions in finding more specific building features. Firstly, observations of buildings were done using the street view tool in Google maps. These observations together with information from energy performance certificates made it possible to develop useful Machine Learning models. Secondly, the Machine Learning models were developed, tested and optimized to get the best accuracy. The most accurate model was used to predict building categories and specific building characteristics. Based on this information, suggestions about potential renovation actions were designed.

The investigation showed that it was possible to use Machine Learning to predict and gather more information about the building stock. Depending on what was supposed to be predicted the result varied. It was easier to predict building categories, with an accuracy of about 90%, than building characteristics which resulted in an accuracy in between 67-93%. Based on the predictions suggestions about reasonable renovation actions were presented, with energy savings around 35%, to contribute to the long-term renovation strategy.

**Key words:** Machine learning, renovation actions, energy efficiency, apartment building stock, RISE

# Sammanfattning

Det Svenska flerbostadshusbeståndet från åren 1945-1975 är på väg att nå slutet på sin tekniska livslängd. Byggnaderna från denna tidsperiod är i stort behov av renovering samt energieffektiviserande åtgärder för att minska energianvändningen och möjliggöra fortsatt användning av byggnaderna i framtiden, samtidigt som ekonomiskt utsatta personer har råd att bo kvar i byggnaderna. Dagens utmaning är att en del särdrag hos byggnader, som behövs för att uppskatta renoveringspotentialen, saknas. Tack vare det faktum att samtliga EUs medlemsländer måste presentera en långsiktig renoveringsstrategi, som främjar investering av renovering för de byggnader som är i behov av det, intresserar sig Sveriges beslutsfattare kring denna frågeställning. För att göra renoveringstrategin realistisk behöver fler byggnadsspecifika särdrag tas fram. Kännetecknen för flerbostadshusbeståndet kan tas fram genom tillämpning av genererade maskininlärningsmodeller. Särdragen förväntas bidra till utvecklingen av en hållbar långsiktig renoveringsstrategi för Sverige.

Projektet är utformat för att undersöka möjliga lösningar att identifiera byggnadsspecifika särdrag hos flerbostadshus från aktuell tidsperiod. Först utfördes observationer av byggnader genom att använda Google street view verktyget i Google maps. Denna information i kombination med information från energideklarationer gjorde det möjligt att utveckla användbara maskininlärningsmodeller. Därefter utvecklades, testades och optimerades maskininlärningsmodellerna för att uppnå en så hög träffsäkerhet som möjligt. Modellerna med bäst träffsäkerhet användes för prediktion av byggnadskategori samt byggnadskaraktistik. Baserat på denna information lämnades förslag på renoveringsplaner.

Projektet visade att det var möjligt att använda maskininläring för att förutse och således samla mer information om beståndet. Beroende på vad som skulle predikteras varierade resultatet. Det var enklare att förutse byggnadskategori, där en träffsäkerhet på ungefär 90% uppnåddes, jämfört med byggnadskaraktistik som resulterade i träffsäkerheter mellan 67-93%. Baserat på dessa prediktioner presenterades förslag på möjliga renoveringsplaner, med uppnådd energibesparing runt 35%, för att bidra till den långsiktiga renoveringstrategin.

**Sökord:** Maskininläring, renoveringsåtgärder, energibesparing, flerbostadshusbeståndet, RISE

# Innehåll

|   |             |
|---|-------------|
| <b>Förord</b>   | <b>ii</b>   |
| <b>Abstract</b>   | <b>iii</b>  |
| <b>Sammanfattning</b>   | <b>iv</b>   |
| <b>Begreppslista</b>  | <b>viii</b> |
| <b>1 Introduktion</b>   | <b>1</b>    |
| 1.1 EU-direktiv som utgångspunkt för energibesparing . . . . .                  | 1           |
| 1.2 Syfte, mål och frågeställningar . . . . .                                   | 3           |
| 1.2.1 Syfte . . . . .   | 3           |
| 1.2.2 Mål . . . . .   | 3           |
| 1.2.3 Frågeställningar . . . . .  | 4           |
| 1.3 Avgränsningar . . . . .   | 4           |
| 1.4 Disposition . . . . .   | 4           |
| <b>2 Teoretisk bakgrund</b>   | <b>5</b>    |
| 2.1 Tidsperioder för det svenska flerbostadshusbeståndet . . . . .              | 5           |
| 2.1.1 Folkhemmet - bostäder till rimliga hyror . . . . .                        | 5           |
| 2.1.2 Rekordåren - majoritet Miljonprogrammet . . . . .                         | 6           |
| 2.2 Flerbostadshusbeståndets byggnadskategorier 1945-1975 . . . . .             | 6           |
| 2.2.1 Lamellhus . . . . .   | 6           |
| 2.2.2 Skivhus . . . . .   | 7           |
| 2.2.3 Punkthus . . . . .  | 7           |
| 2.2.4 Loftgångshus . . . . .  | 7           |
| 2.2.5 Radhus . . . . .  | 7           |
| 2.2.6 Annan kategori . . . . .  | 7           |
| 2.3 Kännetecken och karakteristik hos byggnader 1945-1975 . . . . .             | 8           |
| 2.3.1 Fasadmaterial . . . . .   | 8           |
| 2.3.2 Takform . . . . .   | 8           |
| 2.3.3 Takfot . . . . .  | 9           |
| 2.3.4 Balkongutformning . . . . .   | 10          |
| 2.4 Energideklarationen redovisar en byggnads energiprestanda . . . . .         | 11          |
| 2.4.1 Energiklass en skala från A till G . . . . .                              | 11          |
| 2.4.2 Uppvärmad boarea och energiprestanda . . . . .                            | 12          |
| 2.5 Byggnadssektorn och ett ökat intresse för energifrågor . . . . .            | 12          |
| 2.6 Energieffektivisering i fokus . . . . .                                     | 13          |
| 2.6.1 Renoveringsåtgärder med hänsyn tagen till byggnadskarakteristik . . . . . | 13          |
| 2.6.2 Bevarandevärden . . . . .   | 14          |
| 2.6.3 Lönsam energieffektivisering: Saga eller verklighet . . . . .             | 14          |
| 2.6.3.1 Beräkningsunderlag . . . . .  | 16          |
| 2.7 Data över Sveriges flerbostadshusbestånd . . . . .                          | 18          |
| 2.7.1 Byggnadsspecifik information - det stora datasetet . . . . .              | 18          |
| 2.7.2 En delmängd av det stora datasetet - det lilla datasetet . . . . .        | 18          |

|          |  |           |
|----------|--|-----------|
| 2.8      | Maskininlärning . . . . .  | 18        |
| 2.8.1    | Övervakad eller icke övervakad ML . . . . .                              | 19        |
| 2.8.2    | Klassificeringsalgoritm . . . . .  | 20        |
| 2.8.3    | Normalisering . . . . .  | 21        |
| 2.8.4    | Outliers . . . . .   | 22        |
| 2.8.5    | Test- och träningsdata . . . . .   | 22        |
| 2.8.6    | Träffsäkerhet . . . . .  | 22        |
| 2.8.7    | Överanpassning . . . . .   | 22        |
| 2.8.8    | Cross validation . . . . .   | 23        |
| 2.8.9    | Confusion matrix . . . . .   | 23        |
| <b>3</b> | <b>Maskininlärning som verktyg för att prediktera byggnadsparametrar</b> | <b>25</b> |
| 3.1      | Datahantering - att lära känna data . . . . .                            | 25        |
| 3.1.1    | Observation och framtagning av data . . . . .                            | 25        |
| 3.1.2    | Kontroll och kvalitetssäkring av framtagen data . . . . .                | 27        |
| 3.1.3    | Balanserad data med fler observationer . . . . .                         | 28        |
| 3.1.4    | Byggnadsparametrar som avses predikteras . . . . .                       | 28        |
| 3.1.5    | Tillgängliga features . . . . .  | 29        |
| 3.1.6    | Genererade features . . . . .  | 29        |
| 3.2      | Visualisering - metodik för att finna mönster . . . . .                  | 30        |
| 3.3      | Dataförberedning - möjliggör maskininlärning . . . . .                   | 32        |
| 3.3.1    | Borttagning av loftgångshus . . . . .                                    | 32        |
| 3.3.2    | Borttagning av datapunkter . . . . .                                     | 32        |
| 3.3.3    | Val av features . . . . .  | 33        |
| 3.4      | Maskininlärningsmodeller - tillvägagångssätt vid generering . . . . .    | 34        |
| 3.4.1    | Generering av modeller för logistisk regression . . . . .                | 36        |
| 3.4.2    | Generering av modeller för support vector machines . . . . .             | 36        |
| 3.4.3    | Generering av modeller för neurala nätverk . . . . .                     | 37        |
| 3.5      | Maskininlärningsmodeller - utvärdering och urval . . . . .               | 39        |
| 3.5.1    | Neurala nätverk exkluderas . . . . .                                     | 39        |
| 3.5.2    | Vad baseras urvalet på? . . . . .  | 39        |
| 3.5.3    | Förenkling av modeller . . . . .   | 40        |
| 3.5.4    | Slutgiltigt val av modeller . . . . .                                    | 40        |
| 3.5.4.1  | Byggnadskategori . . . . .   | 40        |
| 3.5.4.2  | Byggnadskaraktistiker . . . . .  | 41        |
| 3.6      | Prediktion på det svenska flerbostadshusbeståndet . . . . .              | 42        |
| 3.6.1    | Validering av prediktion . . . . .                                       | 43        |
| <b>4</b> | <b>Framtagning av energibesparande renoveringsplaner</b>                 | <b>44</b> |
| 4.1      | Renoveringsplaner . . . . .  | 44        |
| 4.2      | Erhållen energibesparing . . . . .                                       | 45        |
| 4.3      | Förväntad kostnad . . . . .  | 47        |
| <b>5</b> | <b>Resultat</b>  | <b>49</b> |
| 5.1      | Maskininlärning - träffsäkerhet och prediktion . . . . .                 | 49        |
| 5.1.1    | Genererade modeller och dess träffsäkerhet . . . . .                     | 49        |
| 5.1.2    | Procentuell fördelning i det svenska flerbostadshusbeståndet . . . . .   | 50        |
| 5.1.3    | Validering av prediktion . . . . .                                       | 51        |
| 5.2      | Renoveringsplaner - energibesparing och kostnad . . . . .                | 51        |
| 5.2.1    | Energibesparing och kostnad . . . . .                                    | 55        |
| 5.2.2    | Känslighetsanalys . . . . .  | 56        |



|          |   |           |
|----------|---|-----------|
| <b>6</b> | <b>Diskussion</b>   | <b>58</b> |
| 6.1      | Maskininlärning - resonemang och förtydligande . . . . .              | 58        |
| 6.1.1    | Datahantering - att lära känna data . . . . .                         | 58        |
| 6.1.2    | Visualisering - metodik för att finna mönster . . . . .               | 60        |
| 6.1.3    | Dataförberedning - möjliggör maskininlärning . . . . .                | 60        |
| 6.1.4    | Maskininlärningsmodeller - tillvägagångssätt vid generering . . . . . | 60        |
| 6.1.5    | Maskininlärningsmodeller - utvärdering och urval . . . . .            | 61        |
| 6.1.6    | Prediktion på det svenska flerbostadshusbeståndet . . . . .           | 63        |
| 6.2      | Renoveringsplaner - bakomliggande tankar . . . . .                    | 64        |
| 6.3      | Resultatdiskussion och analys . . . . .                               | 65        |
| 6.3.1    | Användandet av maskininlärning och träffsäkerhet . . . . .            | 65        |
| 6.3.2    | Procentuell fördelning av byggnadsparametrar . . . . .                | 66        |
| 6.3.3    | Lämpliga renoveringsplaner . . . . .                                  | 68        |
| 6.3.4    | Energibesparing och kostnad . . . . .                                 | 69        |
| 6.3.5    | Brister och förbättringsmöjligheter . . . . .                         | 70        |
| <b>7</b> | <b>Slutsats</b>   | <b>72</b> |

# Begreppslista

**Byggnadsparamterar** - Samlingsnamn för byggnadskategori och byggnadskaraktistiker

**EPC** - Energideklaration (eng. Energy Performance Certificate)

**Features** - Mätbart särdrag, kännetecken eller karaktistisk som förklarar ett observerat objekt

**Flerbostadshus** - En byggnad med flera bostäder under samma tak

**Klimatskalet** - Omfattar de delar av byggnaden som gränsar mot den yttre omgivningen, det vill säga tak, ytterväggar, grunden, fönster och dörrar

**Lågenergifönster** - Fönster med lågt U-värde

**Normalårskorrigerig** - Möjliggör jämförelse av lokaluppvärmningsdata mellan olika perioder oberoende av den aktuella utomhustemperaturen

**Nyttjanderätt** - betyder att man har rättigheten att bruka någon annans egendom.

**Outlier** - Ett observerat värde som skiljer sig kraftigt från övriga observerade värden

**Primärenergitalet** - Beräkningen av primärenergitalet tar hänsyn till den levererade energin till byggnaden och är ett mått på byggnadens energiprestanda

**SEV** - Förkortning av Saga eller verklighet [2], enbart förekommande i kapitel 4

**TET** - En byggnadsparameter som beskriver kombinationen att en byggnad har takutsprång och inte tegelfasad

**Topografi** - Terrängens fysiska höjdskillnader

**Träffsäkerhet** - Möjliggör utvärdering av klassificeringsmodeller inom maskininläring. Den del av förutsägelser som modellen får rätt dividerat med det totala antalet förutsägelser.

**Tilläggsisolering** - Isolering som läggs utanpå en byggnads klimatskal

**U-värde** - Mäter isoleringsförmågan i en byggnadsdel, även kallad värmegenomgångskoefficient

**Utfall** - Output i maskininlärningsmodellerna. De olika alternativ en byggnadsparameter kan anta.

**Värmeåtervinning** - Ett ventilationssystem där frånluften värmer upp tilluften för en byggnad. Mindre energi behöver användas vid uppvärmning.

# Kapitel 1

## Introduktion

### 1.1 EU-direktiv som utgångspunkt för energibesparing

Under de senaste åren har medlemsländerna i EU blivit väl medvetna om de klimatförändringar som råder. Detta har bidragit till ett ökat samarbete för att minska energianvändningen runt om i Europa. Mål utfärdas som säkerställer att arbetet för att minska byggnaders klimatpåverkan fortskrider. Ett mål som EU har satt upp innebär att samtliga byggnader ska energieffektiviseras så att byggnadssektorn blir koldioxidfri 2050. För att uppnå målet har EU utfärdat flertalet direktiv, varav ett kallas *Energy performance of buildings directive* (EPBD), som fokuserar på byggnaders energiprestanda [3, 4].

Sverige måste förhålla sig till de riktlinjer som EU-direktiven innebär. EPBD, som infördes 2002 och uppdaterades 2018, ställer krav på byggnaders energiprestanda. Medlemsländerna har 20 månader på sig att implementera de nya reglerna i landets lagar. Europeiska kommissionen kräver att varje medlemsstat utfärdar en långsiktig renoveringsstrategi som stöd för det nationella byggnadsbeståndet. Att minska energianvändningen blir på detta vis mer och mer förverkligat i Sverige och EU [5].

Med detta direktiv från Europeiska kommissionen som bakgrund efterfrågas en långsiktig nationell renoveringsstrategi för det svenska flerbostadshusbeståndet. Boverket och Energimyndigheten ansvarar tillsammans för att ta fram denna strategi på uppdrag av Regeringen. I den nationellt uppsatta renoveringsstrategin ska, enligt Europeiska kommissionen, en färdplan ingå där medlemsstaterna noggrant beskriver de åtgärder och den mätbarhet landet har för att arbetet mot det långsiktiga 2050-målet ska kunna uppnås. Färdplanen ska dessutom innehålla tydliga milstolpar för arbetet år 2030, 2040 och 2050. I milstolparna ska det framgå hur dessa kommer att bidra till de energieffektiviseringsmål som unionen har satt upp. En uppdaterad renoveringsstrategi, innehållandes information om kostnadseffektiva renoveringsmetoder som tar hänsyn till byggnadstyp och klimatzon, rapporteras vart tredje år [6]. Under hösten 2019 sker en uppdatering av strategin som innehåller förändringar sedan den senaste versionen. Strategin

omfattar i huvudsak information om energieffektiviserande åtgärder i form av planerade renoveringar. I strategin framgår det också vad som kan försvåra antalet renoveringar i flerbostadshus och arbetet med att energieffektivisera en byggnad. En renovering betyder inte att byggnaden blir mer energieffektiv automatiskt, det måste till specifika åtgärder för att uppnå detta [7].

Det finns flera pågående projekt i Sverige som kan underlätta att renoveringsstrategin följs och att EU:s krav uppnås. Ett projekt är *Nationell byggnadsspecifik information* (NBI) som syftar till att kartlägga renoveringsbehovet i det svenska flerbostadshusbeståndet. NBI leds utav Research Institutes of Sweden (RISE) och ämnar att ta fram nyttig information till olika aktörer inom Sveriges bostadsbestånd. I huvudsak undersöks energideklarationerna från 2008 och 2018 för att få en ökad förståelse för utvecklingen av bostadsbeståndets energiprestanda under denna period och för att kunna prediktera en fortsatt utveckling. Utifrån energideklarationerna går det att förstå vad som har bidragit till en minskad energianvändning i det svenska flerbostadshusbeståndet de senaste åren och hur detta kan upprätthållas. En central drivkraft för NBI-projektet är FN:s globala hållbarhetsmål. Dessa hållbarhetsmål syftar till att uppnå minskad ojämlikhet, hållbara städer och samhällen samt att bekämpa klimatförändringen [8].

Utöver RISE forskning i NBI arbetar forskningsprogrammet E2B2 med att bidra till en betydande omställning i energisystemet. Då en tredjedel av Sveriges totala energianvändning är kopplat till bebyggelsen ligger fokus på att energieffektivisera denna sektor på ett så hållbart sätt som möjligt. Genom E2B2 finansierar Energimyndigheten forskning som ska bidra till energieffektivt byggande och boende [9].

För att förstå vilka energieffektiviseringsåtgärder som är lämpliga att applicera är det viktigt att veta hur bostadsbeståndet ser ut samt vilken typ av byggnad som är i störst behov av renovering. En stor andel av bostadsbeståndet byggdes under mitten av 1900-talet när det rådde bostadsbrist i Sverige [10]. Under efterkrigstiden byggdes först det så kallade Folkhemmet men 1964 antog Regeringen ett reformprogram, under namnet *Samlat program för samhällets bostads- och markpolitik* som var ett program för bostadsbyggande i Sverige 1965-1975. Det byggdes en miljon bostäder under tio år som kom att kallas Miljonprogrammet. Dessa hus har en teknisk livslängd på 50 år och denna gräns har nu passerats. Detta innebär att byggnaderna har brister i olika stor utsträckning [11].

Miljonprogrammets byggnader har kritiserats på olika sätt genom åren. Kritiken har riktats mot byggnadernas utseende, placering och funktionalitet [12]. På senare år har fokus skiftat och kritiker menar att byggnaderna inte lever upp till den energiprestanda som de borde [13]. Detta blir problem då Sverige har högt uppsatta miljömål och en omfattande renoveringsstrategi som måste uppfyllas.

Renovering, med syfte att förbättra energiprestandan hos dessa byggnader, är efterfrågat. Dock medför energieffektiviserade åtgärder, som exempelvis tilläggsisolering, omfattande investeringar. Dessutom görs ofta standardhöjande åtgärder i samband med denna typ av renovering, vilket medför hyreshöjningar som de boende i områdena kan få svårt att ha råd med [14]. Faktum kvarstår dock, att dessa byggnader behöver rustas upp inom en snar framtid, för att Sverige ska kunna nå sina uppsatta mål och förväntningar [13].

Byggnader från denna tidsperiod har olika utseende och funktionalitet. Att hitta lämpliga energibespa-

rande renoveringsåtgärder, på ett kostnadseffektivt sätt, som fungerar på samtliga byggnader kan bli en utmaning. Denna vetenskap har lett till att en forsargrupp på det svenska forskningsinstitutet RISE har tagit fram en metodik för att generera byggnadsspecifika renoveringsförslag. RISE använder information i form av byggnadskarakteristiker från både energideklarationer och Lantmäteriet. Detta för att få en bättre och djupare förståelse om det svenska flerbostadshusbeståndet från aktuell tidsperiod. Förväntningen är att inom en snar framtid kunna utveckla modeller, för att hitta ännu mer byggnadsspecifika renoveringsförslag.

För att optimera renoveringstakten för det svenska flerbostadshusbeståndet behövs mer byggnadsspecifik kunskap. Detta projekt ämnar att, med hjälp av maskininlärning, ta fram ny information kring det svenska flerbostadshusbeståndet som tidigare saknats. Tillvägagångssättet blir att observera ett urval av byggnader och notera värdefull byggnadsspecifik information. Karakteristiker som kan vara intressanta att observera är bland annat vilken hustyp det handlar om, vilket fasadmateriäl byggnaden har, takformen, om det finns ett takutsprång samt hur balkongen är utformad. Dessa observationer kan utföras med hjälp av verktyg i Google maps. Med denna information insamlad, för ett urval av byggnader, kan motsvarande karakteristiker predikteras på resten av byggnadsbeståndet med hjälp av maskininlärning. När kunskap finns angående hur byggnaderna är utformade, kan olika scenarior tas fram kring vilka byggnader som borde prioriteras att renoveras i första hand. Olika maskininlärningsmetoder kommer testas och utvärderas för att hitta den optimala modellen för denna typ av prediktion.

Genom att göra prediktioner på detta sätt kommer man i framtiden kunna utföra mer byggnadsspecifika energibesparande renoveringar. Den långsiktiga renoveringsstrategin kommer gynnas och på så sätt kommer Sverige, mer effektivt, leva upp till EU:s uppsatta krav.

## 1.2 Syfte, mål och frågeställningar

### 1.2.1 Syfte

Syftet med projektet är att bidra med ny användbar information gällande byggnadsparametrar för det svenska flerbostadshusbeståndet som kan användas vid utformningen av den uppdaterade renoveringsstrategin. Byggnader som omfattas av studien är flerbostadshus byggda åren 1945-1975.

### 1.2.2 Mål

Syftet kan konkretiseras enligt följande:

Studien ämnar att, med hjälp av byggnadsspecifik information, utveckla och förbättra den metodik som RISE tillämpat vid framtagning av energibesparande renoveringsplaner. Med ett utökat dataunderlag och maskininlärning kommer byggnadsparametrar predikteras som anses nödvändiga för att med mer precision föreslå lämpliga renoveringsåtgärder. Utifrån energibesparing och kostnad, ska renoveringsplaner presenteras uppskalad på nationell nivå. För att åstadkomma detta listas projektets preciserade mål nedan:

- Utöka dataunderlaget till åtminstone 500 observationer
- Träna, utvärdera och jämföra olika maskininlärningsmodeller för klassificering
- Prediktera byggnadsparametrar på flerbostadshusbeståndet
- Presentera förslag på renoveringsplan

### 1.2.3 Frågeställningar

- Hur och med vilken träffsäkerhet kan maskininläring användas för klassificering av olika byggnadsparametrar?
- Hur fördelar sig byggnadsparametrar procentuellt för det svenska flerbostadshusbeståndet från 1945-1975?
- Hur kan lämpliga renoveringsplaner för det svenska flerbostadshusbeståndet från 1945-1975 se ut?
- Vad resulterar renoveringsplanerna i för energibesparing och kostnad?

## 1.3 Avgränsningar

I detta projekt studeras enbart det svenska flerbostadshusbeståndet från tidsperioden 1945-1975. Denna tidsperiod utgörs av byggnadsepokerna Folkhemmet och Rekordåren. Projektet behandlar klassificeringsproblem, därav kommer inte metoder som avser linjär regression att utvärderas.

## 1.4 Disposition

Detta projekt är uppbyggt av sju separata kapitel. Uppdelningen är gjord för att särskilja information så att den ska bli så enkel och tydlig för läsaren som möjligt. Efter det inledande kapitlet, följer kapitel 2, som presenterar den teoretiska bakgrunden till projektet. Detta kapitel kombinerar bakgrunden till projektet med teori som är nödvändig för att kunna följa och förstå det fortsatta arbetets struktur. Kapitel 3 beskriver den metod som använts vid framtagandet av maskininlärningsmodeller och prediktion av byggnadsparametrar. Därefter följer ytterligare ett metodavsnitt, kapitel 4, som fokuserar på framtagandet av förslag på renoveringsplaner. Metodavsnitten följs av resultat i kapitel 5 och diskussion i kapitel 6. I diskussionsdelen förs resonemang kring de metoder som tillämpats under projektets gång samt studiens resultat. Projektets slutsatser presenteras i kapitel 7.

# Kapitel 2

## Teoretisk bakgrund

*Detta kapitel ämnar att ge läsaren en ökad förståelse för det svenska flerbostadshusbeståndet från åren 1945-1975 genom att presentera den bakgrund som är relevant för att kunna följa och förstå det fortsatta arbetet i projektet. Kapitlet inleds med en presentation av aktuella tidsepoker och byggnadsparametrar och avslutas med ett omfattande avsnitt om maskininlärning.*

### 2.1 Tidsperioder för det svenska flerbostadshusbeståndet

Det svenska flerbostadshusbeståndet kan delas in i olika byggnadsepoker. Detta projekt kommer undersöka flerbostadshusbeståndet från åren 1945-1975. Denna tidsperiod innefattar byggnadsepokerna Folkhemmet och Rekordåren. Epokerna beskrivs mer ingående nedan.

#### 2.1.1 Folkhemmet - bostäder till rimliga hyror

Under och efter andra världskriget diskuterades boendesituationen för de svenska medborgarna. Något som diskuterades var bland annat att tillgången till en bostad var en social rättighet. I bostaden skulle det i varje rum inte behöva bo fler än två personer, köket och badrummet oräknat. Ett uttryck som blev välkänt var *"Hela svenska folket ska försees med goda hygieniska bostäder till rimliga hyror"*. Bakgrunden till denna byggnadsepok blev därför den svenska bostadspolitik. Målet om att uppföra många nya bostäder skulle nås med hjälp av statliga bostadslån och räntesubventioner. Förhoppningen var att ett stort bostadsbyggnadsprogram skulle lösa problemet med den svåra trångboddheten. Kommunerna ansvarade för att sätta upp egna bostadsbyggnadsprogram där politikerna skulle beräkna behovet av bostäder och planera utbyggnaden. Kommunerna kom att domineras av platseffektiva flerbostadshus [10].

Folkhemmet byggdes upp under 1940- och 1950-talet med syfte att under denna tid skapa bostäder åt alla, oberoende av samhällsklass eller inkomst. Byggnaderna från denna tid kan uppfattas som relativt anonyma. Detta kan bero på att förutsättningarna för att bygga inte var optimala och att det fanns

knappa resurser. Framförallt rådde brist på både material och arbetskraft under tidigt 1940-tal vilket försvårade byggandet. Trots detta är byggnaderna från denna tid överlag robusta och har många inslag av en gedigen hantverksmässighet [10].

### 2.1.2 Rekordåren - majoritet Miljonprogrammet

Under denna byggnadsepok, 1961-1975, byggdes ett stort antal bostäder. Ungefär två tredjedelar av dessa utgörs av flerbostadshus medan resterande är småhus. Denna period överlappar Miljonprogrammet. Av de 1,4 miljoner bostäder som byggdes under Rekordåren utgör en miljon av dessa Miljonprogrammet [15].

Miljonprogrammet är ett samlingsnamn och ett resultat av en statlig satsning för svenska bostäder som byggdes under åren 1965-1975. Ett riksdagsbeslut togs att under en tioårsperiod bygga en miljon bostäder, därav det omtalade namnet. En *bostad* innebär en självständigt fungerande lägenhet i ett flerbostadshus eller ett enskilt småhus [15]. Bakgrunden till Miljonprogrammet målas ofta upp som en följd av en låg bostadsproduktion i Sverige, men enligt Boverket var inte detta anledningen. Redan innan perioden för Miljonprogrammet hade Sverige en hög bostadsproduktion med hela 80 000 producerade bostäder bara under 1963. Boverket menar att bakgrunden till Miljonprogrammet istället grundar sig i ett politiskt beslut där det skulle bevisas att bostadsproduktionen kunde ökas ytterligare. Detta genom att tillämpa en mer industriell produktion där stora områden byggdes industriellt på samma sätt [11].

Utbyggnadsstrategin varierade under Miljonprogrammets tioårsperiod. Från början, mellan åren 1965-1971, var utbyggnadstakten hög och fokus låg på byggandet av flerbostadshus. Efterfrågan på flerbostadshuslägenheter avtog och fanns inte kvar 1971, därför strukturerades byggandet om och fokus skiftade istället till byggandet av småhus. Med småhus menas mindre byggnader som ingår i Miljonprogrammet men inte utgör en del av flerbostadshusbeståndet. Boverket menar att människor tenderar att tänka på Miljonprogrammet som ett projekt med höga betonghus byggda i stora kluster. Höga betonghus utgör en del av Miljonprogrammet men majoriteten av Miljonprogrammets bostäder består av låga, så kallade lamellhus, med vanligtvis två till fyra våningar [11].

## 2.2 Flerbostadshusbeståndets byggnadskategorier 1945-1975

Flerbostadshusbeståndet från Folkhemmet och Rekordåren består av flertalet olika byggnadskategorier. Följande avsnitt beskriver de olika byggnadskategorier som studeras i detta projekt, flerbostadshus samt radhus. Vilken typ av byggnad det är spelar en avgörande roll när en renoveringsplan ska utfärdas.

### 2.2.1 Lamellhus

Den mest återkommande hustypen från den studerade tidsperioden är lamellhusen. Närmare bestämt nästan hälften av flerbostadshusen utgörs av låga lamellhus. En typisk karakteristik för dessa byggnader är att de generellt består av två till fyra våningar. Att husen är låga beror på att detta förenklade byggprocessen genom att byggnaderna då inte var i stort behov av hiss. Ofta kunde lamellhusen anpassas efter topografin och möjliggjorde bevarandet av ursprunglig grönska och växtlighet på byggplatsen. Husen



placerades vanligtvis parallellt eller rätvinkligt i förhållande till varandra [2]. I figur 2.1 (a) återfinns ett exempel som visar ett typiskt lamellhus.

### 2.2.2 Skivhus

Det tydligaste kännetecknet för denna byggnadskategori är att byggnaderna är höga med vanligtvis 8-9 våningar. Husen byggdes inte högre än så på grund av att detta var den högsta höjd brandkåren kunde nå med stegbil. Dessutom, om husen inte byggdes högre, uteblev krav på byggnaden såsom brandisolering i trapphusen och att två hissar behövde byggas. Skivhusen är ofta placerade parallellt med ett avstånd mellan sig som avgjordes av byggkranarnas räckvidd. De friliggande skivhusen återfinns på plan mark, då produktionsmetoden krävde detta [2]. Se figur 2.1 (b) för ett exempel av ett typiskt skivhus.

### 2.2.3 Punkthus

Punkthusen är också höga och består av 6-9 våningar. Med samtliga lägenheter sammankopplade i ett gemensamt trapphus centrerat i byggnaden blir resultatet ett långsmalt högt hus. Punkthusen är ofta placerade i kluster, med ett antal likadana hus i närheten av varandra [2]. Figur 2.1 (c) är ett exempel av ett punkthus.

### 2.2.4 Loftgångshus

Ett loftgångshus är ett flerbostadshus som är utrustat med en eller flera utanpåliggande gångar längs hela fasaden. Entré till byggnadens bostäder sker via gångarna på utsidan av huset istället för via traditionella trapphus [16]. Loftgångshusen byggdes i huvudsak under den senare perioden av de studerade åren. Anledningen till att loftgångshusen blev mer populära i slutet av byggåren berodde framförallt på att det fanns ett stort intresse att öka antalet lägenheter som betjänades av samma hiss och på så sätt sänka kostnaderna för densamma. Utöver detta fanns det intresse för att i större utsträckning integrera de boende med varandra [2]. Se figur 2.1 (d) för typiska drag hos ett loftgångshus med tydliga loftgångar längs fasaden.

### 2.2.5 Radhus

Det som karakteriserar ett radhus är att minst tre självständiga bostäder är direkt sammankopplade till varandra. Radhus tillhör, till skillnad från ovan beskrivna byggnadstyper, inte kategorin flerbostadshus. För att klassas som ett flerbostadshus ska det finnas gemensamma bostadsfunktioner såsom till exempel gemensamma entréer, vilket uteblir för byggnadskategorin radhus [17].

### 2.2.6 Annan kategori

Utöver nämnda byggnadskategorier finns det ytterligare byggnader från de aktuella byggåren. Dessa byggnader kan inte kategoriseras på ett konsekvent sätt eftersom de skiljer sig mycket åt från fall till fall. I detta projekt kategoriseras svårdefinierade byggnader tillsammans som "Annan kategori".



Figur 2.1: Typhus för de olika byggnadskategorierna [2].

## 2.3 Kännetecken och karakteristik hos byggnader 1945-1975

Detta avsnitt ämnar att förklara vanliga byggnadskaraktistiker som är intressanta och har betydelse vid energibesparande renoveringar.

### 2.3.1 Fasadmaterial


Byggnader från den undersökta tidsperioden är försedda med olika fasadmaterial. Materialen skiljer sig åt i funktion och beständighet. Ett visst material kan vara fördelaktigt för en del hustyper och ett annat material kan vara fördelaktigt för andra. Fasadmaterialet finns i huvudsak där för att skydda byggnaden mot väder och vind men även för att ge huset ett arkitektoniskt uttryck. Faktorer som kan avgöra valet av fasad kan vara bostadsområdets karaktär, byggnadens förväntade livslängd och underhållsaspekter [18]. Några vanliga fasadmaterial från de aktuella åren är: tegel, trä, puts, skivor, betongelement och plåt.

### 2.3.2 Takform

Flerbostadshus är försedda med tak av varierande utformning. En vanligt förekommande takform i Sverige är *sadeltaket* vilket har ett triangelformat utseende, se figur 2.2 (a). Vinkeln vid taknocken, där de båda taksidorna möts, varierar. Däremot går samtliga tak med denna spetsiga utformning under kategorin

sadeltak. Att taket är byggt på detta vis gör att snö och annat lätt kan glida av och på så sätt tyngs inte taket ned [19]. En annan takutformning som är relativt vanlig i Sverige är *pulpettak*. Denna takform har enbart fall åt det ena hållet och kan därför liknas vid en halv triangel, se figur 2.2 (b). Vinkeln på taket är relativt liten men finns där för att underlätta för regn och snö att glida av [19].

En annan vanligt återkommande takform i Sverige är ett låglutande variant som ofta uppfattas och kategoriseras som platt tak, se figur 2.2 (c). Taket har en mycket liten vinkel, uppemot 14 grader. Risker med platt tak är att vatten kan ansamlas och göra skada, men detta kan undvikas genom att taket konstrueras på ett korrekt vis. En korrekt konstruktion innebär att enbart material avsedda för platt tak används, balkar är rätt dimensionerade och ytmaterialet är noga utvalt för att passa för det aktuella taket [20]. Det är inte ovanligt att platta tak är försedda med någon form av fläktrum [21], exempel på detta återfinns i figur 2.2 (d).




Figur 2.2: De olika takformerna; sadeltak [22], pulpettak [23], platt tak [24] och fläktrum [25].

### 2.3.3 Takfot

Takfoten, vilken också kan benämnas takskägg eller takutsprång, är den nedre delen av taket på en byggnad och återfinns i anslutning till husväggen. Takfoten kan antingen ligga i linje med husväggen eller

sticka ut en bit. Den är till för att skydda husets ytterväggar mot regn och vind. I de fall där takutsprånget saknas och taket slutar precis i linje med husväggen är taket ofta utrustat med en hängränna längs takslutet för att skydda väggarna mot regn. Skilda meningar råder huruvida takfoten finns av estetiska eller praktiska skäl [26]. Figur 2.3 nedan visualiserar skillnaden mellan *takutsprång* och *inte takutsprång* hos en byggnad.




Figur 2.3: Bild till vänster: hus försett med takutsprång. Bild till höger: hus utan takutsprång.


#### 2.3.4 Balkongutformning

En balkong kan antingen vara indragen, se figur 2.4 (a), eller oindragen, se figur 2.4 (b). En indragen balkong innebär att en del av balkongen hamnar innanför ramen för klimatskalet. Detta kan innebära otäta utfackningsväggar vilket inte är att föredra ur ett energiperspektiv. När en balkong är oindragen är den placerad i linje med byggnadens ytterfasad [27]. Utöver detta kan en balkong vara helt inglasad. En inglasad balkong är energibesparande för hela byggnaden tack vare att den tillförda energin för uppvärmning kan minskas [28].

(a) Indragen balkong



(b) Oindragen balkong



Figur 2.4: Indragen [29] och oindragen balkong [30].

## 2.4 Energideklarationen redovisar en byggnads energiprestanda

Energideklaration är ett dokument som redovisar en byggnads energiprestanda. Den används när en bostad ska säljas eller hyras ut. Här återfinns information rörande energianvändningen för en specifik byggnad. Den boende får via energideklarationen reda på hur mycket energi som används och jämförelser kan således göras mellan olika byggnader [31]. Boverket ansvarar för att energideklarationen innehåller korrekt information samt ger råd om hur byggnaden kan energieffektiviseras [32]. En deklaration ska göras vart tionde år och efter att en ny byggnad tagits i bruk måste en energideklaration utföras inom två år [33]. Varje energideklaration har en unik kod som kallas för formulär-ID vilken gör det möjligt att skilja energideklarationer åt. Figur 2.5 visar hur en energideklaration ser ut.

Boverket har utfärdat krav på fyra olika tillfällen då byggnader behöver energideklareras [31].

### Byggnader som behöver energideklareras:

- Nya byggnader.
- Byggnader vars golvarea är större än 250 kvadratmeter och ofta besöks av allmänheten.
- När byggnader upplåts med nyttjanderätt.
- När byggnader säljs.

### 2.4.1 Energiklass en skala från A till G

I energideklarationen återfinns även information om vilken energiklass den aktuella byggnaden tillhör. Energiklasserna fördelas på en skala A till G som visar hur mycket energi en byggnad använder. Skalan är graderad så att A representerar den lägsta energianvändningen byggnaden kan ha och G representerar den högsta. Byggnader som byggs idag har ett krav, vilket denna skala utgår från, på vilken energianvändning som tillåts. Kravet, och därmed skalan, tar hänsyn till parametrar som: *vilken typ av byggnad det är, hur den är uppvärmd* samt *vilken geografisk placering den har* [34].

Sedan januari 2019 baseras energiklass på primärenergitalet istället för den specifika energianvändningen. Primärenergitalet tas fram genom att studera den levererade energin till byggnaden och inte, som tidigare, genom att enbart studera hur mycket energi byggnaden förbrukar [34].

|      |   |                                       |
|------|---|---------------------------------------|
| I    | <p>Sammanfattning av</p> <h1>ENERGIDEKLARATION</h1>   |                                       |
| II   | Byggnadens adress   |                                       |
| III  | Kommun  |                                       |
| IV   | Nybyggnadsår:   |                                       |
| V    | Energideklarations-ID:  |                                       |
| VI   | <p><b>ENERGIKLASSER</b></p>   | <p>DENNA BYGGNADS<br/>ENERGIKLASS</p> |
|      |   | X                                     |
|      | Energiprestanda, primärenergital:   | XI                                    |
|      | Krav vid uppförande av ny byggnad, primärenergital:   | XII                                   |
|      | Specifik energianvändning (tidigare energiprestanda):   | XIII                                  |
|      | Uppvärmningssystem:   | XIV                                   |
|      | Radonmätning:   | XV                                    |
|      | Ventilationskontroll (OVK):   | XVI                                   |
|      | Åtgärdsförslag:   | XVII                                  |
| VII  | Energideklarationen i sin helhet finns hos byggnadens ägare.  |                                       |
| VIII | För mer information:<br><a href="http://www.boverket.se">www.boverket.se</a>  |                                       |
| IX   | Sammanfattningen är upprättad enligt Boverkets föreskrifter och allmänna råd (2007:4) om energideklaration för byggnader. |                                       |
|      | Energideklarationen är utförd av:   | XVIII                                 |
|      | Energideklarationen är giltig till:   | XIV                                   |

Figur 2.5: Figuren föreställer en energideklaration [31].

### 2.4.2 Uppvärmad boarea och energiprestanda

Uppvärmad boarea,  $A_{temp}$ , avser invändig area för våningsplan, vindsplan och källarplan som värms till mer än 10 °C. Denna area är energirelaterad och ska kunna beräknas både för nya och redan befintliga byggnader [35].  $A_{temp}$  ligger till grund för beräkningen av en byggnads energiprestanda som i sig är ett mått vilket beskriver en byggnads energianvändning. Energiprestanda presenteras i energideklarationen och bygger på byggnadens normalårskorrigerade energianvändning. Enheten för  $A_{temp}$  är [ $m^2$ ] och för energiprestanda [ $kWh/(m^2 \cdot \text{år})$ ] [36].

## 2.5 Byggnadssektorn och ett ökat intresse för energifrågor

Många byggnader som byggs idag är energieffektiva. Detta tack vare att det finns ett ökat intresse för energi- och miljöfrågor inom byggnadssektorn. Det är positivt att många nybyggda byggnader är energisnåla, men det finns också ett behov att energiprestandan hos de äldre byggnaderna ses över [37]. 2017 stod sektorn bostäder och service för nästan 40% av Sveriges totala energianvändning [38].

Den 10 juni 2016 fattade Regeringen beslut om Sveriges mål för energieffektivisering till 2030. Målen innebär att Sverige ska ha 50% mer effektiv energianvändning 2030 jämfört med 2005 [39–41]. För att Sverige ska nå de uppsatta målen måste förändringar ske idag, förändringar som bland annat inkluderar renovering av gamla flerbostadshus med dålig energiprestanda. När byggnaderna ändå ska renoveras bör fokus ligga på att samtidigt sänka byggnadernas energianvändning. Det finns olika åtgärder som kan appliceras för att sänka energibehovet. En betydande åtgärd är att se över klimatskalet hos byggnaden och utföra någon form av tilläggsisolering om detta är möjligt [42].

## 2.6 Energieffektivisering i fokus

Enligt Naturvårdsverket finns det flera olika metoder för att nå minskad energianvändning. Beteendeförändring hos befolkningen är en effektiv metod medan energieffektivisering i form av tekniska åtgärder är en annan [32]. På byggnader kan energieffektivisering från tekniska åtgärder uppnås genom exempelvis tilläggsisolering, byte av belysning eller genom uppdatering av ventilation. Det finns styrmedel för att reglera och underlätta energieffektiviseringar. Olika styrmedel inriktar sig mot olika sektorer, där byggnader och byggande utgör en av dessa sektorer [32]. Nedan beskrivs faktorer att ta hänsyn till vid utförandet av renoveringsåtgärder.

### 2.6.1 Renoveringsåtgärder med hänsyn tagen till byggnadskarakteristik

Faktorer som är av betydelse vid energibesparande renovering är byggnadens utformning och karaktäristik. Dessa spelar en avgörande roll för vilka renoveringsåtgärder som har potential att bidra till en betydande energieffektivisering på ett så kostnadseffektivt sätt som möjligt. Framförallt byggnadens tak, fasadmaterial samt balkongens utformning är av betydelse. Kombinationen av olika karaktäristiker resulterar i olika lämpliga renoveringsåtgärder. Varje byggnad är unik och dess konstruktion och skick är helt avgörande för val av åtgärder. Detta avsnitt behandlar renoveringsåtgärder utifrån de karaktäristiker som beskrevs i avsnitt 2.3.

Olika åtgärder kan appliceras på taket beroende på dess utformning. Är det ett sadeltak går det att göra en omfattande isolering på vindsvåningen eller lägga solceller för att optimera energiprestandan [43]. Är taket försett med takutsprång är det enkelt att utföra en tilläggsisolering på huset. Om taket däremot saknar takutsprång och byggnaden ska tilläggsisoleras måste ett längre takutsprång byggas vilket innebär en omfattande renovering [44].

Beroende på vilket fasadmaterial en byggnad har är olika renoveringsåtgärder lämpliga. Äldre byggnader ska uppnå ett liknande U-värde som nyare byggnader. Detta kan uppnås genom till exempel tilläggsisolering. Tilläggsisolering lämpar sig bäst på de fasader som inte utgörs utav tegel, med hänsyn tagen till bevarandevärde, se avsnitt 2.6.2. Tilläggsisoleringen bidrar inte bara med ett förbättrat U-värde utan även en förbättrad täthet i byggnaden [44]. På en del byggnader skiljer sig gavelmaterialet från fasadmaterialiet på övriga väggar. När materialen på dessa byggnadsdelar skiljer sig åt skulle det kunna försvåra en potentiell tilläggsisolering. Enbart tilläggsisolering på husets ytterväggar längs långsidorna

av byggnaden skulle i så fall vara möjligt i de fall då gavelsiorna består av tegel [45].

Lämpliga renoveringsåtgärder skiljer sig också åt beroende på hur de ursprungliga balkongerna hos byggnaden är utformade. I ett pilotprojekt i Brogården i Alingsås gjordes åtgärder på en indragen balkong. Efter åtgärderna inkluderades en del av den ursprungliga balkongen innanför klimatskalet och utgjorde istället en del av vardagsrummet vilket visade sig vara energibesparande. Nya fristående balkonger byggdes i detta fall i linje med klimatskalet. Indragna balkonger orsakar ofta en oönskad köldbrygga vilket upptäcktes i ett pilotprojekt som utfördes på Katjas gata i Göteborg. Utöver att dra in en indragen balkong och bygga en ny i linje med klimatskalet kan en åtgärd vara att glasa in balkongen för att uppnå energibesparing. Detta gjordes på Maratonvägen i Halmstad [44].

### 2.6.2 Bevarandevärden

Ytterligare en betydande faktor som behöver tas i beaktning vid renovering är PBL, Sveriges Plan- och bygglag. I lagen framgår att en byggnad som är särskilt värdefull ur ett kulturhistoriskt perspektiv ska bibehållas och vårdas på ett sådant sätt att dess utformning och tekniska egenskaper bevaras [46]. Fastighetsägaren eller byggherren är ansvarig för att bygglagen följs.

Inte bara slott och herrgårdar anses vara kulturhistoriskt värdefulla. Enkla byggnader som är typiska för en viss plats bedöms ofta ha ett kulturhistoriskt värde. Vad som bedöms ha ett kulturhistoriskt värde kan vara alltifrån byggnadstekniker och materialval till byggnadens stil eller form [47]. Kommunerna har en detaljplanering som används både för enstaka fastigheter och för mindre stadsdelar. Detaljplaneringen användas för lokala politiska ställningstaganden om bebyggelsens utformning och förhindrar på så sätt att byggnader förvanskas. Bestämmelserna i planen är juridiskt bindande och rör både rättigheter och begränsningar för förändring i området. Detaljplanen är i bruk tills dess att den avskaffas eller ersätts med en ny detaljplan. Detta innebär att den renovering som krävs för att optimera byggnadens energiprestanda kan försvåras när hänsyn tas till denna lag ur ett kulturhistoriskt perspektiv [46].

### 2.6.3 Lönsam energieffektivisering: Saga eller verklighet

För att avgöra vad som är optimala renoveringsåtgärder gäller det att se byggnaden som ett helhetssystem. En åtgärd på klimatskalet i kombination med upprustning av ventilationssystem kan ge det bästa utfallet ur ett energimässigt och ekonomiskt perspektiv. När det utförs en ombyggnation eller renovering av en byggnad bör fokus ligga på att göra byggnaden mer energieffektiv. 2017 stod sektorn bostäder och service för nästan 40% av Sveriges totala slutliga energianvändning. För att dra ned på energianvändningen inom denna sektor krävs omfattande energieffektiviserande åtgärder och ett förändrat beteendemönster hos personer som brukar byggnaderna. Byggnader har en lång teknisk livslängd och de åtgärder som utförs påverkar byggnadens prestanda många år framöver [48].

En studie inom detta område har utförts gemensamt av VVS företagen, institutionen för energiteknik vid Kungliga Tekniska Högskolan och White arkitektur AB för att underlätta för energieffektiviserande åtgärder, i samband med renovering, i framtiden. Studien, med namnet "Lönsam energieffektivisering:



Saga eller verklighet”, resulterade i tre olika paket av åtgärder för att möjliggöra energieffektivisering av olika byggnadskategorier. I studien applicerades paketen på åtta olika *typbyggnader* framtagna från tidsperioden 1950-1975. Resultatet visar vilken energibesparing som kan uppnås med respektive åtgärd samt kostnaden för densamma. Beräkningsunderlag från studien presenteras övergripande senare i denna rapport, se avsnitt 2.6.3.1 nedan.

Syftet med studie var att möjliggöra matchning mellan *typbyggnader* från studien med befintliga, verkliga, byggnader i Sverige från den aktuella tidsperioden. På detta sätt går det att förstå vilken renoveringsåtgärd som är lämplig för den aktuella, befintliga, byggnaden. Matchningen visar hur stor energibesparing en renovering skulle innebära för en specifik byggnad. Även kostnaden för renoveringsåtgärderna går att prediktera. I tabell 2.1 nedan beskrivs de *typbyggnader* som ingår i studien och vilka karakteristiker som kännetecknar dessa. Benämningarna på byggnadskategorierna är direkt hämtade från studien.

Tabell 2.1: Karakteristik för de olika typbyggnaderna från studien *Saga eller verklighet* [2].

| Byggnadskategori      | Byggår     | Fasadmaterial                                 | Takform                             | Vån | Balkong   |
|-----------------------|------------|---|-------------------------------------|-----|-----------|
| Lamellhus, gasbetong  | 1950-talet | Puts el. tegel                                | Sadeltak                            | -*  | Varierar  |
| Lamellhus, betong     | 1960-1975  | Äldre: puts el. tegel<br>Nyare: betongelement | Äldre: sadeltak<br>Nyare: pulpettak | -   | Indragen  |
| Loftgångshus          | 1960-1975  | Tegel   | Pulpettak                           | -   | Indragen  |
| Lamellhus, formgjuten | 1970-1975  | Trä, puts, plåt                               | Pulpettak                           | -   | Oindragen |
| Punkthus              | 1950-1960  | Puts  | Pulpettak                           | 6-9 | Varierar  |
| Skivhus, lättbetong   | 1965-1975  | Puts  | -                                   | 8-9 | Indragen  |
| Skivhus, fasadelement | 1965-1975  | Betongelement                                 | -                                   | 8-9 | Indragen  |
| Hus, elementbyggt     | 1965-1975  | Betongelement                                 | -                                   | -   | Oindragen |

\* Markering (-) betyder att denna parameter är ospecificerad i studien.

En sammanfattning av åtgärdspaketen från studien *Lönsam energieffektivisering: Saga eller verklighet* beskrivs nedan. I tabell 2.2 presenteras procentuell energibesparing per typbyggnad och åtgärdspaket [2].

### Paket 1 - Driftoptimering

Detta är det renoveringspaket som kräver minst resurser och kostnad. Exempel på åtgärder är:

- Sänkning av temperatur i trapphus till 15 °C
- Installation av styrning för trapphusbelysning och byte till lågenergilampor
- Justering av innetemperatur till 21 °C

### Paket 2 - Effektivare komponenter och enkla tillägg

Beräkningarna för detta paket förutsätter att åtgärderna från paket 1 utförts. Detta åtgärds paket ställer högre krav på planering och kostnaderna blir högre. Exempel på åtgärder är:

- Tilläggsisolering av vindsbjälklag, 20 cm
- Byte av utrustning i tvättstugor till moderna maskiner
- Installation av lägenhetsvis mätning av tappvarmvatten

### Paket 3 - Långsiktigt hållbar klimatskal och ventilation

För att kunna utföra detta paket krävs att fasadrenovering är planerad. Dessutom förutsätter beräkningarna att även paket 1 och 2 genomförs. Exempel på åtgärder i paket 3 är:

- Ombyggnad av ventilationssystem för värmeåtervinning ur frånluften
- Byte av fönster till lågenergifönster
- Tilläggsisolering av fasader, 10 cm

Tabell 2.2: Procentuell energibesparing per byggnadstyp och renoveringspaket [2].

| Byggnadskategori      | Paket 1 [%] | Paket 2 [%] | Paket 3 [%] |
|-----------------------|-------------|-------------|-------------|
| Lamellhus, gasbetong  | 14,2        | 25,2        | 63,8        |
| Lamellhus, betong     | 10,1        | 25,2        | 59,7        |
| Loftgångshus          | 11,8        | 22,6        | 53,5        |
| Lamellhus, formgjuten | 9,3         | 25,9        | 58,5        |
| Punkthus              | 17,6        | 25,4        | 63,6        |
| Skivhus, lättbetong   | 6,4         | 22,8        | 57,3        |
| Skivhus, fasadelement | 10,5        | 24,6        | 51,8        |
| Hus, elementbyggt     | 9,4         | 23,8        | 48,4        |

#### 2.6.3.1 Beräkningsunderlag

Kostnaderna för ovan presenterade renoveringspaket har beräknats i studien. För paket 2 och 3 motsvarar denna kostnad marginalkostnaden för de energieffektiviserande åtgärder som utförs i samband med renovering. Mer konkret har man i studien tagit upp som exempel att kostnaden vid byte av fönster innefattar de extra kostnader som tillkommer för att välja ett fönster som är mer energieffektivt än det normala. Som ett andra exempel innebär marginalkostnaden vid en planerad fasadrenovering den extra kostnad som tillkommer för personal och material som tilläggsisolering innebär. Beräkningarna har innefattat investeringskostnader, kostnader för nyinvestering efter tioårsperioder samt energikostnader för el

och fjärrvärme. Dessutom beräknades årliga driftskostnader för värmeåtervinning i paket 3 som således belastar det årliga kassaflödet [2].

Investeringskostnaderna skiljer sig åt beroende på vilket paket som ska tillämpas. För paket 1 rör det sig om investeringskostnader för bland annat kontrollsystem, för paket 2 effektivare maskiner i tvättstugor och för paket 3 tilläggsisolering.

Utöver investeringskostnaderna finns beräkningar som avser de kostnader som rör nyinstallationer som behöver göras efter tio, tjugo respektive trettio år. För de mindre omfattande och därmed billigare investeringarna är tidsintervallen mer frekventa. För de mer omfattande åtgärderna förväntas ingen nyinstallation behövas under en längre tidsperiod. Efter fyrtio år antas samtliga renoveringsåtgärder behövas utföras igen.

I studien har analyser gjorts för att undersöka hur mycket energi, i form av el och fjärrvärme, som används årligen per typbyggnad. Beräkningar och simuleringar gjordes i studien för att ta reda på hur stor energibesparing som kunde uppnås årligen för respektive typbyggnad och renoveringspaket. Till detta presenterades en procentuell energibesparing för respektive fall, se tabell 2.2.

Energien, el och fjärrvärme, beräknades före och efter planerad renovering. Priset för energin före och efter multiplicerades med ett energipris för el och fjärrvärme som antogs öka med åren på grund av inflation. Differensen mellan priserna som beräknades utgjorde sedan underlag för att få en förståelse för vilken återbetalningstid investeringarna hade. Återbetalningstid är ett verktyg som används för att kontrollera hur snabbt en investering betalar sig själv. Detta möjliggör jämförelser mellan olika investeringar. I studien användes *Internräntemetoden* (IRR). Ekvationen 2.1 med ingående variabler presenteras nedan.

$$-G + \sum_{i=1}^n \frac{C_i}{(1+k)^i} = 0 \quad (2.1)$$

G: Grundinvestering

i: Antal år

n: Återbetalningstid

C: Kassaflöde aktuellt år

(*Differensen i kostnad aktuellt år efter renovering gentemot vad kostnaden hade varit om ingen renovering ägt rum*)

k: Kalkylränta

## 2.7 Data över Sveriges flerbostadshusbestånd

RISE förfogar över en databas med information från cirka 50 000 unika energideklarationer från åren 1945-1975. Dataraderna är unika tack vare energideklarationernas formulär-ID. Denna data har sammankopplats med data från Lantmäteriet vilket tillsammans lett till en databas innehållandes byggnadsspecifik information om det svenska flerbostadshusbeståndet. Varje enskild datarad i denna databas motsvarar ett formulär-ID med en adress samt byggnadspecifik information kopplad till den aktuella adressen. Databasen benämns i detta projekt *det stora datasetet*. För att möjliggöra analys med maskininlärning, för att i detta projekt kunna ta fram ytterligare information om byggnaderna, har ett urval av cirka 2 000 datarader plockats ut från det stora datasetet och bildar ett mindre dataset. Detta dataset kallas i detta projekt *det lilla datasetet*.

### 2.7.1 Byggnadsspecifik information - det stora datasetet

Det stora datasetet innehåller 48 524 unika datarader. Varje datarad innehåller information hämtad från energideklarationer och Lantmäteriet. En datarad sorteras ut baserat på det unika formulär-ID som återfinns i energideklarationen och är kopplat till en unik adress. Information om byggnaderna, för aktuella adresser, i det stora datasetet är bland annat särdrag som: byggår, uppvärmd area (Atemp) och antal våningar. Från detta dataset har sedan ett mindre dataset genererats: *det lilla datasetet*.

### 2.7.2 En delmängd av det stora datasetet - det lilla datasetet

Detta dataset är ett urval av cirka 2 000 adresser på fastigheter från det stora datasetet. En fastighet är ett samlingsnamn för en eller flera byggnader. RISE har genererat det lilla datasetet genom att fokusera på fastigheter med ett högt värde på Atemp. Anledningen till detta var för att öka sannolikheten att det lilla datasetet skulle innehålla flertalet större byggnader och fastigheter. RISE menar att de ville ha stora fastigheter, högt värde på Atemp, med i urvalet för att åtgärder på stora fastigheter skulle resultera i en större energibesparing.

## 2.8 Maskininlärning

Maskininlärning (ML) är intressant för användning i många olika sammanhang. ML sägs ofta vara en del av artificiell intelligens (AI) som i sin tur har en väldigt bred definition. AI beskrivs som ett datorsystem vilket strävar efter att efterlikna mänsklig intelligens. Tanken med AI är att skapa tillräckligt "smarta" automatiserade system för att lösa problem som det tidigare behövts mänsklig inverkan på för att lösa [49]. En definition av AI, framtagen av University of Oxford, presenteras nedan [49]:

*The theory and development of computer systems able to perform tasks normally requiring human intelligence, such as visual perception, speech recognition, decision-making, and translation between languages.*

Andrew Ng (Andrew Ng, Adjunct professor Stanford University) beskriver ML med hjälp av definitionen som Arthur Samuel myntade 1959 [50]. Denna definition lyder:

*The field of study that gives computers the ability to learn without being explicitly programmed.*

Ng menar att ett datorsystem kan ”lära sig” av tidigare erfarenheter och på så sätt bli bättre på att utföra en uppgift. Detta liknas med hur vi människor lär oss nya saker. Vi använder oss av tidigare erfarenheter för att avgöra hur vi ska agera i en ny situation. Precis så fungerar även maskininlärningsmodeller. Idag används ML inom ett brett spektrum användningsområden. Exempel på användningsområden är självkörande bilar, röstigenkänning eller bildigenkänning [50].

Vid användandet av maskininlärning finns det alltid tillgång till någon form av input-data ( $X$ ). Input-datan används i maskininlärningsmodellen med syfte att prediktera ett särskilt utfall ( $y$ ). Om det finns tillgång till en stor mängd input-data, kan modellen använda sig av detta för att ”lära sig” hur prediktionen ska ske och på så sätt bli bättre och mer träffsäker [51]. Figur 2.6 visualiserar processen för maskininlärning. Inuti den blå boxen viktas en uppsättning av parametrar som utgör grunden för maskininlärningsmodellen. Dessa parametrar avgör utfallet ( $y$ ) utifrån vad som skickas in som input ( $X$ ).



Figur 2.6: I den blå boxen sker maskininlärning som resulterar i varierande utfall  $y$ .

### 2.8.1 Övervakad eller icke övervakad ML

Det finns två olika typer av maskininlärning, övervakad och icke övervakad.

Övervakad maskininlärning innebär att output-data ( $y$ ) är känd för en viss kombination av input-data ( $X$ ). Maskininlärningsmodellen skapas med hjälp av denna data och genom att iterera över flera exempel är förhoppningen att modellen ska ”lära sig” mönster. Modellen kan sedan utsättas för ny data, där output-datan ( $y$ ) är okänd, och prediktera en förväntad output [51].

Icke övervakad maskininlärning innebär att input-data ( $X$ ) är känd men output-data ( $y$ ) saknas. Syftet med denna typ av maskininlärning är inte att prediktera ett särskilt utfall. Istället används denna metodik när output saknas men man vill hitta samband i data och försöka samla output-data ( $y$ ) i olika kluster. Den största svårigheten med icke övervakad maskininlärning är att det inte är lika enkelt att kontrollera hur bra modellen är, eftersom det inte finns något ”facit” som för övervakad maskininlärning. Detta är anledningen till namnet, icke övervakad maskininlärning [51].

## 2.8.2 Klassificeringsalgoritm

Ett vanligt tillvägagångssätt inom ML är att dela in variabler i två kategorier: kvantitativa och kvalitativa. Exempel på kvantitativa variabler är årtal eller ålder, värdena är tal. Exempel på kvalitativa variabler är ögonfärg eller kön, värdena är inte tal.

Vid prediktion av en kvantitativ variabel är *linjär regression* användbart. Linjär regression bygger på linjära samband och predikterar ett utfall med ekvation 2.2 [51].

$$\beta_0 + \beta_1 X = y \quad (2.2)$$

Vid klassificering, vilket innebär prediktion av en kvalitativ variabel, används med fördel andra metoder. Ekvation 2.3 är en vidareutveckling av ekvation 2.2 med skillnaden att möjliga resultat hamnar inom intervallet 0 och 1. Om exempelvis ögonfärg ska predikteras kan 0 representera bruna ögon medan 1 kan representera blå ögon. Resultatet av ekvation 2.3 visar sannolikheten att ögonfärgen är blå. När sannolikheten är känd, kan en slutsats dras kring vad modellen skall prediktera när denna ekvation används [51]. För att förtydliga förses ekvationen med input-data ( $X$ ) och genererar således sannolikheter för olika utfall. Det utfall med störst sannolikhet avgör vad output-data ( $y$ ) blir.

$$p(X) = \frac{e^{\beta_0 + \beta_1 X}}{1 + e^{\beta_0 + \beta_1 X}} \quad (2.3)$$

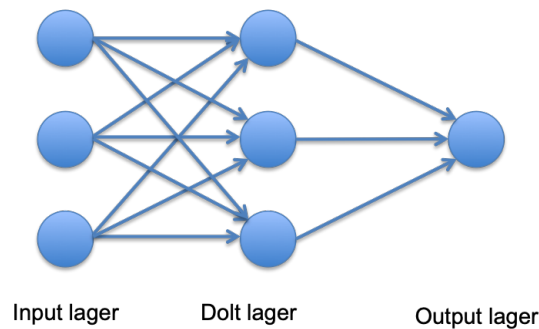
De ingående variablerna,  $\beta_0$  och  $\beta_1$ , i ekvation 2.2 och 2.3 antar varierande värden då maskininlärningsmodellen tränas och optimeras.

Nedan presenteras tre användbara metoder för klassificering:

- **Logistisk Regression (LR)** är en statistisk metod som utgår från ekvation 2.3. Genom att använda resultatet, det vill säga sannolikheten för ett visst utfall, kan det avgöras om modellen ska prediktera det ena eller det andra utfallet. En linjär avgränsning (eng. *linear decision boundary*), som separerar utfallen från varandra, används som beslutsgrund [50, 51]. Logistisk regression är applicerbart även då utfallen är fler än två.
- **Support Vector Machines (SVM)** är också en metodik som används vid klassificering. SVM har många likheter med LR, de skillnader som förekommer medför dock att dessa metoder är fördelaktiga i olika situationer. SVM är inte begränsat till en linjär avgränsning. I denna metod kan istället olika olinjära avgränsningar (eng. *nonlinear decision boundaries*) testas för att uppnå bästa resultat [52]. I detta projekt används två inställningsparametrar, *cost* och *gamma*, för att optimera

och erhålla så enkla SVM-modeller som möjligt. Cost och gamma är parametrar som avgör hur olinjära utfallen kan bli. Ett högt värde på parametrarna innebär en mer olinjär avgränsning och risk finns för överanpassning, se avsnitt 2.8.7. Lägre värde resulterar i en mer linjär avgränsning och risk finns att modellen blir för generell [53].

- **Neurala Nätverk (NN)** används brett inom ML. Ett neuralt nätverk har en nätstruktur som utgörs av lager och noder, detta för att försöka efterlikna den mänskliga hjärnan. Det finns alltid minst två lager, ett input lager och ett output lager, med minst en nod vardera. De lager i strukturen som hamnar mellan input lagret och output lagret kallas för dolda lager. De olika noderna kommunicerar med varandra, viktas och lär sig för att i slutändan kunna prediktera ett utfall. Antalet lager och noder varieras för att uppnå en optimal struktur för det aktuella ändamålet [50]. Figur 2.7 beskriver ett exempel på hur ett neuralt nätverk kan se ut. Detta exempel består av ett dolt lager med tre noder.



Figur 2.7: Exempel på ett neuralt nätverk bestående av ett dolt lager med tre noder.

### 2.8.3 Normalisering

I maskininlärningsprocesser är det inte ovanligt att input-värdena varierar inom olika intervall med betydande storleksskillnader. I dessa fall är det viktigt att normalisera datan för att få mer jämförbara inputparametrar. Normaliseringen skalar om samtliga inputparametrars värden så att de hamnar inom intervallet 0 till 1. Detta underlättar prediktion eller förutsägelse av ett visst utfall [54]. Det finns olika metoder som används vid normalisering. I detta projekt används en metod som kallas minmax-normalisering. Här skalas värdet om genom att det sätts i förhållande till det lägsta och högsta värdet inputparametern antagit i aktuellt dataset. Metoden beskrivs med ekvation 2.4 nedan.

$$y = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (2.4)$$

### 2.8.4 Outliers

En outlier (sv. *extremvärde*) är en datapunkt som har ett extremt avvikande värde och därför sticker ut från övriga datapunkter. Med en överskådlig plot är det enkelt att identifiera outliers i datasetet. Outliers kan dyka upp av olika anledningar, den mest troliga orsaken är att något blivit fel vid datainsamling på grund av den mänskliga faktorn. För att få bukt med problemet är det första steget att studera datapunkten noggrant för att förstå varför den sticker ut från övriga datapunkter. Efter utvärdering kan datapunkten troligtvis plockas bort eller korrigeras [51].

Om outliers bevaras och finns med i datasetet under modellframtagningen kan det resultera i att tydliga mönster blir svåridentifierade. Ett exempel på att outliers kan orsaka problem är att ett extremt avvikande värde resulterar i betydande förändring av medelvärdet.

### 2.8.5 Test- och träningsdata

För att kunna utvärdera en ML-modell delas datan upp i en träningsdel och en testdel. Detta för att träna modellen på träningsdelen och därefter utvärdera modellen på testdelen. Andelen data som hamnar under träningsdelen respektive testdelen varierar beroende på mängden data som finns tillgänglig, vad som ska modelleras och vem som modellerar [51]. Se figur 2.8 för en visualisering av uppdelningen.



Figur 2.8: Exempel på uppdelning av datan i tränings- respektive testdata.

### 2.8.6 Träffsäkerhet

Träffsäkerheten möjliggör utvärdering av klassificeringsmodellens precision. Det vill säga, när en modell tränas kan träffsäkerheten mätas genom att kontrollera hur många gånger modellen predikterar rätt utifrån sitt förutbestämda facit. Ekvation 2.5 beskriver detta matematiskt [51].

$$\text{Träffsäkerhet} = \frac{\text{Antal korrekt predikterade förutsägelser}}{\text{Totalt antal förutsägelser}} \quad (2.5)$$

### 2.8.7 Överanpassning


Överanpassning innebär att modellen blir *för* specifikt reglerad av träningsdatan. Modellen tar stor hänsyn till varje datapunkt i träningsdatan vilket medför att den även tar med och modellerar för brus.



Detta gör att modellen blir sämre på att generalisera och hitta mönster när den utsätts för ny osedd data. Ett kännetecken för en överanpassad modell är att dess träffsäkerhet på träningsdatan (*tidigare sedd data*) är mycket högre än träffsäkerheten på testdatan (*ny osedd data*). Att kontrollera om överanpassning uppstår används för att göra en rimlighetsanalys av träffsäkerheten för modellen [51, 55].

### 2.8.8 Cross validation

Cross validation (CV) är ett verktyg som är användbart när bättre förståelse behövs om hur stabil en framtagen ML-modell är. Stabiliteten avgörs genom att testa modellen på osedd data flertalet gånger och erhålla en hög genomsnittlig träffsäkerhet. Den ursprungliga träningsdatan delas in i provisoriska tränings- och testdelar på ett liknande sätt som beskrevs i avsnitt 2.8.5. Denna indelning görs vanligtvis tio gånger och i detta fall kallas metoden *tenfold cross validation* och testas på tio olika provisoriska testset. Att modellen ska köras flera gånger på olika dataset är tidskrävande men ger en mer optimerad och utvärderad modell i slutändan [51]. Figur 2.9 visar uppdelningen av träningsdatan vid ten fold cross validation.



Figur 2.9: Visualisering av provisoriska tränings- och testdelar i cross validation.

Träffsäkerheten loggas samtliga tio gånger när modellen körs och ett genomsnitt av träffsäkerheten för dessa kan beräknas. När modellen senare testas på det ursprungliga testsetet anses modellen vara välfungerande om den genomsnittliga träffsäkerheten för cross validation överensstämmer med träffsäkerheten på det osedda testsetet. Cross validation kan användas vid jämförelser av olika modeller för att validera vilken metod som är mest välfungerande [51].

### 2.8.9 Confusion matrix

När maskininlärning används är det intressant att veta hur väl modellen predikterar. För att utvärdera en modell och för att kontrollera dess robusthet kan en *confusion matrix* användas. Denna matris visar information om vart felet uppstår under prediktion. Denna information är värdefull för att vidare kunna

optimera modellen. I vissa fall behöver ett visst utfall predikteras mer korrekt än ett annat. Detta ligger till grund för att det är viktigt att förstå när utfall blir felbedömda av modellen. Värt att notera är att diagonalen i en confusion matrix representerar de fall där modellen gör en korrekt bedömning av vad som ska predikteras [51]. Två exempel på hur en confusion matrix kan se ut presenteras i figur 2.10 nedan. Exemplet behandlar en modell som ska prediktera ögonfärg hos sammanlagt 100 personer. Exemplet till vänster visar att modellen predikterar korrekt i 60 av 65 fall för blå ögonfärg. Detta motsvarar en träffsäkerhet på 92%, se ekvation 2.6a. För brun ögonfärg predikterar modellen rätt i 20 av 35 fall, vilket ger en träffsäkerhet på 57% se ekvation 2.6b. Den totala träffsäkerheten, som beskrevs i avsnitt 2.8.6, blir 80% för modellen enligt ekvation 2.6c. I exemplet till höger i figuren har modellen en träffsäkerhet på 100% då värden utanför diagonalen är noll.

$$\frac{60}{65} = 92\% \quad (2.6a)$$

$$\frac{20}{35} = 57\% \quad (2.6b)$$

$$\frac{(60 + 20)}{(65 + 35)} = 80\% \quad (2.6c)$$

|          |      | Predikterat |      |
|----------|------|-------------|------|
|          |      | Blå         | Brun |
| Verkligt | Blå  | 60          | 5    |
|          | Brun | 15          | 20   |

|          |      | Predikterat |      |
|----------|------|-------------|------|
|          |      | Blå         | Brun |
| Verkligt | Blå  | 65          | 0    |
|          | Brun | 0           | 35   |

Figur 2.10: Figuren visar två exempel på en confusion matrix.

## Kapitel 3

# Maskininlärning som verktyg för att prediktera byggnadsparametrar

*I detta kapitel beskrivs de moment som utförts för att ta fram optimala maskininlärningsmodeller. Kapitlet avser att bidra med förståelse för vikten av att lära känna datan och beskriver därefter hur modellering och prediktion utförts praktiskt. Kapitlet inleds med en beskrivning hur data samlats in och förberetts. Därefter följer generering och val av maskininlärningsmodeller. När färdiga modeller framställts förklaras slutligen processen att prediktera på hela flerbostadshusbeståndet från åren 1945-1975.*

### 3.1 Datahantering - att lära känna data

I detta projekt användes övervakad maskininlärning som beskrevs i avsnitt 2.8.1. För att bistå modellen med ett förutbestämt facit, output för tränings- och testdata, behövde byggnadsspecifik information samlas in som förklarades i avsnitt 2.2 och 2.3. Ett urval på cirka 500 av de adresser som fanns tillgängliga i det *lilla* datasetet, vilket beskrevs i avsnitt 2.7.2, studerades manuellt med verktyget street view i Google maps. Observationer utfördes genom att husen, på de utvalda adresserna, studerades grundligt för att kunna dokumentera byggnadskategori samt byggnadens karakteristiker. Att identifiera byggnadsparametrar på detta vis var av väsentlig betydelse för att senare kunna klassificera byggnaderna och deras karaktärsdrag med maskininlärning.

#### 3.1.1 Observation och framtagning av data

Observationer i Google maps utfördes parallellt av författarna. För att undvika brister i datan i form av felobservationer togs en metodik fram för hur en observation skulle gå till. Med denna metodik som underlag förväntades samtliga observationer utföras på ett konsekvent sätt. Samstämmighet mellan olika personers bedömning har säkerställts genom att de bedömt samma fastigheter likadant.

Följande tillvägagångssätt användes vid observationerna:

1. Inledningsvis hämtades en av de 500 utvalda adresserna, se avsnitt 3.1, och söktes upp via Google maps.
2. Därefter kontrollerades att Google maps markerade en byggnad som stämde överens med data från energideklarationen. Den information som kontrollerades var antalet våningar som skulle stämma överens med antalet våningar på den observerade adressen. I de fall där adressen var svårtolkad, och inte verkade stämma överens med datan, användes Eniros karttjänst. Eniros karttjänst tillförde ytterligare information och var ofta träffsäker i de fall där verktyget i Google maps var otydligt. Då datan stämde överens, och bilderna var tillräckligt tydliga för att kunna göra en rättvis bedömning av byggnaden, kunde observationen fullföljas.
3. En del observationer kunde inte utföras eftersom det inte var möjligt att komma tillräckligt nära med Google street view för att göra en pålitlig observation. I de fall där observation var omöjlig att utföra på grund av dåliga bilder eller andra faktorer markerades adressen i urvalet av data med att observation *ej var möjlig*.
4. Genom att grundligt granska byggnaden noterades byggnadskategori, se avsnitt 2.2, samt de byggnadskarakteristiker som förklarades i avsnitt 2.3. Utfallen för respektive byggnadsparameter visas i tabell 3.1.

Tabell 3.1: Byggnadsparametrar som observerades.

| Byggnadskategori  | Fasadmaterial     | Balkong           | Takform           | Takfot            |
|-------------------|-------------------|-------------------|-------------------|-------------------|
| Lamellhus         | Trä               | Indragen balkong  | Sadeltak          | Takutsprång       |
| Skivhus           | Puts              | Oindragen balkong | Pulpettak         | Inte takutsprång  |
| Punkthus          | Tegel             | Ingen balkong     | Fläktrum          | Ej möjligt att se |
| Radhus            | Betongelement     | Ej möjligt att se | Platt tak         | -                 |
| Loftgångshus      | Plåt              | -                 | Ej möjligt att se | -                 |
| Annan kategori    | Skivor            | -                 | -                 | -                 |
| Ej möjligt att se | Ej möjligt att se | -                 | -                 | -                 |

5. Om osäkerhet uppstod kring någon av parametrarna ovan diskuterades detta för att komma fram till det bästa svarsalternativet.
6. När byggnaderna studerades upptäcktes ytterligare karakteristiker som skulle kunna vara användbara i vidare arbete. Detta var karakteristiker som återkom vid flertalet observationer. Efter denna upptäckt granskades de redan observerade byggnaderna ytterligare en gång för att addera den nytillkomna informationen och därefter utfördes resterande observationer med de nytillkomna karakteristikerna. De karakteristiker som tillfördes visas i tabell 3.2 nedan.

Tabell 3.2: Tillagda karakteristiker.

| Adderade karakteristiker |                  |                      |                          |
|--------------------------|------------------|----------------------|--------------------------|
| Gavelmaterial            | Inglasad balkong | Obs. ant. våningar   | Fönsterband på lamellhus |
| Trä                      | Ja               | Anger antal manuellt | Ja                       |
| Puts                     | Nej              | -                    | Nej                      |
| Tegel                    | -                | -                    | Inte lamell              |
| Betongelement            | -                | -                    | -                        |
| Plåt                     | -                | -                    | -                        |
| Skivor                   | -                | -                    | -                        |
| Ej möjligt att se        | -                | -                    | -                        |

7. Tre adresser som inte gick att observera med hjälp av Google maps låg i Lund och Burlöv. Dessa byggnader observerades genom besök på plats.

### 3.1.2 Kontroll och kvalitetssäkring av framtagen data

En upptäckt som gjordes när observationerna var klara var att en unik energideklaration kunde innehålla många olika adresser. När fler än en adress är registrerad på samma energideklaration utgör detta dubletter i datan, eftersom varje rad i datan representerar en adress. Dubletter bör undvikas i maskininlärningsprocesser och därför blev det aktuellt att undersöka detta vidare. De datarader som hade identiska formulär-ID, se avsnitt 2.4, plockades bort ur datasetet. På detta sätt strukturerades datan om så att det endast fanns unika datapunkter baserat på formulär-ID i datan. För att undersökningen av det svenska flerbostadshusbeståndet skulle bli så träffsäker som möjligt och spegla hur det faktiskt ser ut i Sverige idag var det viktigt att enbart data med unika formulär-ID behölls och arbetades vidare med. Efter denna korrigering reducerades antalet observationer, hämtade från det lilla datasetet, från 527 till 476 stycken.

Utöver ovan nämnd korrigering gjordes ytterligare förfiningsåtgärder. I de fall där kolumnen *byggnadskategori* fylldes i med svarsalternativet *ej möjligt att se* utifrån observationerna i Google maps beslutades att dessa observationer skulle uteslutas i vidare arbete. Orsaken var att dessa byggnader inte skulle bidra med användbar information till maskininlärningsmodellen. Tre observationer togs bort och antalet observationer som skulle användas vidare i arbetet reducerades till 473 stycken. Samtliga förfiningsåtgärder gjordes för att säkerställa att datan var rättvisande och av hög kvalitet.

De 473 unika observationerna granskades för att ta reda på hur stor del av dessa som utgjordes av respektive byggnadskategori. Resultatet från detta går att se i tabell 3.3 nedan:

Tabell 3.3: Procentuell fördelning av de olika byggnadskategorierna.

| <b>Totalt antal unika observationer: 473</b> |                   |                                   |
|--|-------------------|-----------------------------------|
| <b>Byggnadskategori</b>                      | <b>Antal [st]</b> | <b>Procentuell fördelning [%]</b> |
| Lamellhus                                    | 324               | 68,0                              |
| Loftgångshus                                 | 12                | 2,5                               |
| Punkthus                                     | 21                | 4,4                               |
| Radhus                                       | 12                | 2,5                               |
| Skivhus                                      | 81                | 17,7                              |
| Annan kategori                               | 23                | 4,9                               |

### 3.1.3 Balanserad data med fler observationer

I tabell 3.3 går det att utläsa att lamellhusen utgjorde en dominerande del av antalet observationer. Detta medförde att datan var ojämt fördelad vilket misstänktes kunna medföra problem vid maskininlärningsarbetet. Denna hypotes resulterade i ett beslut att utföra ytterligare observationer av byggnader i kategorier med lägre representation i datasetet. Med fler genomförda observationer förväntades ett mer balanserat dataset erhållas med ökat antal punkthus, radhus och loftgångshus. För att observationerna skulle ske så tidseffektivt som möjligt undersöktes endast byggnader som hade fler än fyra våningar och färre än tre våningar. På detta sätt reducerades risken att göra observationer på ytterligare lamellhus vilket inte var önskvärt. Om adressen som hämtades mot förmodan inte representerade ett punkthus, radhus eller loftgångshus utfördes ingen observation. Denna andra omgång av observationer, 41 stycken, resulterade i en total fördelning som presenteras i tabell 3.4.

Tabell 3.4: Procentuell fördelning av de olika byggnadskategorierna efter andra omgången observationer.

| <b>Totalt antal unika observationer: 514</b> |                  |                                   |
|--|------------------|-----------------------------------|
| <b>Byggnadskategori</b>                      | <b>Antal[st]</b> | <b>Procentuell fördelning [%]</b> |
| Lamellhus                                    | 324              | 63,0                              |
| Loftgångshus                                 | 18               | 3,5                               |
| Punkthus                                     | 36               | 7,0                               |
| Radhus                                       | 32               | 6,2                               |
| Skivhus                                      | 81               | 15,8                              |
| Annan kategori                               | 23               | 4,5                               |

### 3.1.4 Byggnadsparametrar som avses predikteras

Detta avsnitt beskriver vilka byggnadsparametrar som avsågs predikteras med maskininläring, listade i tabell 3.5 nedan. Bakgrunden till denna tabell var att denna byggnadsspecifika information behövdes för att kunna genomföra de energibesparande renoveringspaket, som presenterades i avsnitt 2.6.3, på respektive byggnad.

För att möjliggöra tilläggsisolering som innefattas i paket 3, se avsnitt 2.6.3, var information om fasadmateriell och takutsprång nödvändig. En tegelfasad är ej lämplig för denna renoveringsåtgärd, se avsnitt rörande bevarandevärden 2.6.2. Utöver detta är det fördelaktigt om byggnaden är försedd med takutsprång. Därför genererades en byggnadsparameter som en kombination av dessa två karakteristiker som i detta projekt kom att kallas: *Takutsprång ej tegel* (TET).

Tabell 3.5: De byggnadsparametrar som avsågs predikteras.

| Byggnadsparametrar |
|--------------------|
| Byggnadskategori   |
| Fasadmaterial      |
| Takform            |
| Takfot             |
| TET                |

### 3.1.5 Tillgängliga features

För att kunna arbeta vidare med maskininlärningsprocessen, och möjliggöra prediktion av ovan nämnda byggnadsparametrar, undersöktes samtliga byggnadssärdrag som fanns tillgängliga i det stora datasetet. Särdrag som senare kom att benämnas *features*. Tabell 3.6 visar de features, det vill säga input-data (X) se avsnitt 2.8, som förväntades vara relevanta för vidare arbete med maskininlärningsprocessen och som fanns tillgängliga i redan befintlig data.

Tabell 3.6: Tillgängliga byggnadssärdrag, övervägda som features, hämtade ur det stora datasetet.

| Features                      | Förkortning   | Features                              | Förkortning |
|-------------------------------|---------------|---------------------------------------|-------------|
| Byggår [årtal]                | År            | Energiprestanda [kWh/m <sup>2</sup> ] | EP          |
| Antal våningar [st]           | Vån           | Total energianvändning [kWh]          | -           |
| Ombyggnadsår [årtal]          | -             | Total elanvändning [kWh]              | -           |
| Antal källarplan [st]         | -             | Använd fjärrvärme [kWh]               | -           |
| Antal trapphus [st]           | AT            | Energiklass [-]                       | EK          |
| Atemp [m <sup>2</sup> ]       | -             | Kommunkod [-]                         | -           |
| Antal bostäder [st]           | AB            | Länskod [-]                           | LK          |
| Antal adresser per EPC* [st]  | AEPC          | Postnummer [-]                        | PN          |
| Väderstreck Väst till Öst [-] | V/Ö           | Väderstreck Syd till Norr [-]         | S/N         |
| EPC per fastighet [st]        | EPC/fastighet |                                       |             |

\* EPC (eng. *Energy Performance Certificate*) = Energideklaration

### 3.1.6 Genererade features

Utöver de features som beskrevs i tabell 3.6 ansågs fler features vara nödvändiga som inte fanns tillgängliga i datasetet. Kombinationer av dessa redan befintliga features gjordes för att erhålla nya features som på

ett tydligare sätt förväntades hitta markanta skillnader och mönster till maskininlärningsmodellen. Hur generering av dessa utfördes presenteras i ekvation 3.1-3.6. I tabell 3.7 listas de features som genererades. I diskussionsavsnittet 6.1.1 förklaras tanken bakom dessa features och vad de förväntades tillföra.

$$Atemp \text{ per våning} = \frac{Atemp}{Vån} \quad (3.1)$$

$$Bostäder \text{ per adress} = \frac{AB}{AEPC} \quad (3.2)$$

$$Trapphus \text{ per adress} = \frac{AT}{AEPC} \quad (3.3)$$

$$Atemp \text{ per våning per adress} = \frac{Atemp}{(Vån)(AEPC)} \quad (3.4)$$

$$Atemp \text{ per våning per trapphus} = \frac{Atemp}{(Vån)(AT)} \quad (3.5)$$

$$Antal \text{ trapphus per bostad} = \frac{AT}{AB} \quad (3.6)$$

Tabell 3.7: Genererade features

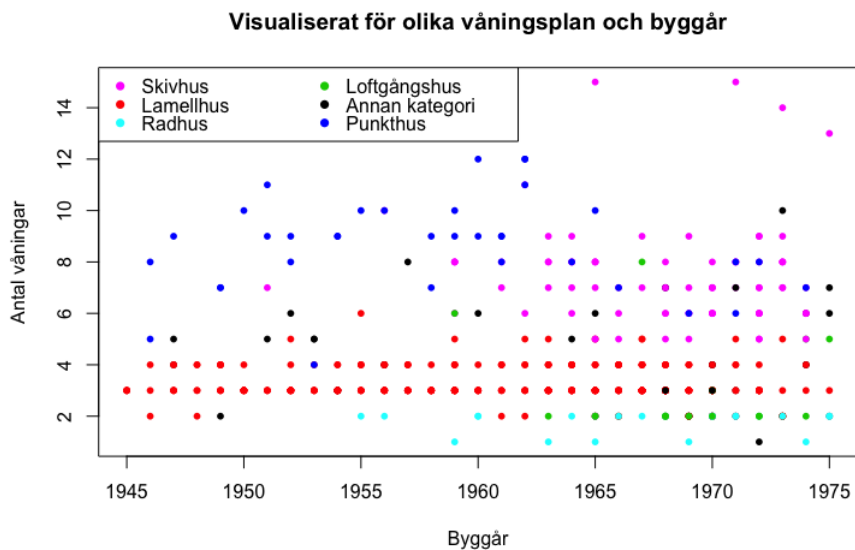
| Genererade features           | Förkortning |
|-------------------------------|-------------|
| Atemp per våning              | AV          |
| Bostäder per adress           | BA          |
| Trapphus per adress           | TA          |
| Atemp per våning per adress   | AVA         |
| Atemp per våning per trapphus | AVT         |
| Trapphus per bostad           | TB          |

## 3.2 Visualisering - metodik för att finna mönster


För att få ytterligare förståelse för hur de olika byggnadsparameterna förhåller sig till olika features, skapades figurer i form av plottar och boxplots. Vid skapandet av plottar sattes byggår på x-axeln för att sedan variera olika features, se tabell 3.6-3.7, på y-axeln. Denna metod genererade flera olika figurer för respektive byggnadsparameter. Ett exempel på hur en sådan plot kunde se ut presenteras i figur 3.1.



Vid skapandet av boxplottar placerades möjliga utfall av de byggnadsparametrar som var önskvärda att prediktera, se tabell 3.5, på x-axeln. Y-axeln varierades med features, se tabell 3.6 och 3.7, på motsvarande sätt som för ovan nämnda plottar. Exempel på en boxplot presenteras i figur 3.2.



Figur 3.1: Antal våningar mot byggår. Varje punkt motsvarar en byggnad.



Figur 3.2: Fördelning av byggår för respektive byggnadstyp.

### 3.3 Dataförberedning - möjliggör maskininlärning

Tillvägagångssättet som beskrevs i avsnitt 3.2 var värdefullt för att få en djupare förståelse för samband i datan. Hypotesen var att plottarna skulle kunna urskilja utfallen för de olika byggnadsparameterna ifrån varandra. Detta visade sig stämma och det upptäcktes exempelvis att för byggnadskategori kunde antal våningsplan urskilja lamellhusen från punkthusen.

Målet med visualiseringarna, i avsnitt 3.2, var att hitta mönster och kluster i datan som kunde avgöra vilka features som skulle kunna vara användbara i maskininlärningsmodellerna. Utöver detta diskuterades vilka andra möjliga features, från energideklarationerna och Lantmäteriet, som förväntades ge ett önskvärt resultat. En kombination av visualiseringarna och diskuterade features medförde att en del features antogs vara viktigare än andra för vidare arbete.

#### 3.3.1 Borttagning av loftgångshus

Det fanns inte några tydliga karakteristiska drag som kunde skilja loftgångshusen från övriga byggnadskategorier i plottarna från avsnitt 3.2. Ett exempel på detta är att, i figur 3.1, gick det inte att urskilja något tydligt mönster av varken byggår eller antal våningar för loftgångshusen. Dessutom visade det sig att andra omgången observationer, som i huvudsak utförts för att utöka andelarna punkthus, radhus och *loftgångshus*, inte resulterade i en betydande ökning av loftgångshusen. Det fanns för få observationer av loftgångshusen, för att de skulle kunna vara värdefulla att ha med i maskininlärningsmodellen, även efter andra omgången observationer.

Att det inte fanns några tydliga karakteristiska drag och att det fanns för få observationer av denna byggnadskategori var två betydande orsaker som medförde att loftgångshusen, efter diskussion tillsammans med forskargruppen på RISE, beslutades att kategoriseras om till någon av de andra byggnadskategorierna. Nya observationer utfördes på enbart loftgångshusen för att de skulle kunna kategoriseras om till någon av de övriga byggnadskategorierna som de stämde bäst överens med. När observationerna utfördes gick det enkelt att avgöra vilken byggnadskategori byggnaden kunde kopplas till. Att detta var en så enkel åtgärd stärkte beslutet om att göra denna omkategorisering av loftgångshus som numera inte längre var en egen byggnadskategori i detta projekt. Loftgångshusen kategoriserades om enligt följande:

1. De låga loftgångshusen klassificerades som radhus eller lamellhus. I de fall där det låga huset hade en gemensam trappuppgång inne i byggnaden klassificerades det som lamellhus och där det istället var en trappuppgång utanför byggnaden klassificerades det som radhus.
2. De högre loftgångshusen, som liknade skivhus, klassificerades som skivhus.

#### 3.3.2 Borttagning av datapunkter

För att generera optimala maskininlärningsmodeller ska så kallade outliers undvikas, se avsnitt 2.8.4. Genom att studera de plottar och boxplottar som genererades i avsnitt 3.2, var det möjligt att bestämma

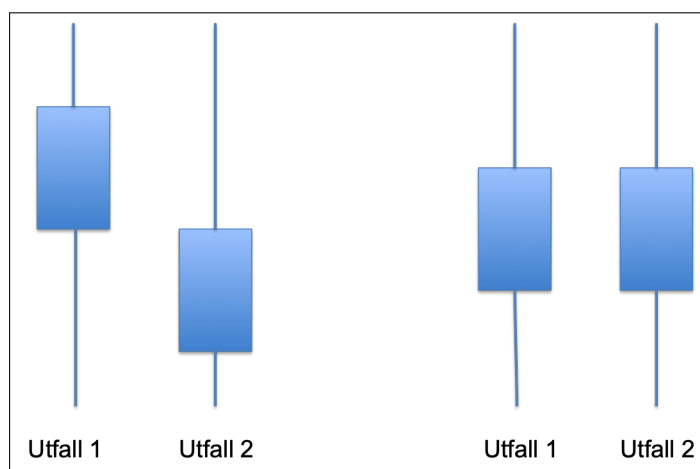
vilka datapunkter som skulle plockas bort eller korrigeras. Orsakerna till varför datapunkter togs bort eller korrigerades varierade. De mest återkommande orsakerna presenteras nedan:

- Datapunkt med markant avvikande värde från resterande värden av samma kategori togs bort från träningsdatan, se avsnitt om outliers 2.8.4.
- Byggnaden var felklassificerad från början. Detta upptäcktes vid en andra omgång av observationer och korrigerades till rätt byggnadskategori.
- Fel antal våningar i inputdatan från energideklarationen. Korrigering utfördes genom att ändra till observerat antal våningar.
- Antal adresser var fel i inputdatan. I de fall där det var möjligt, korrigerades detta till observerat antal adresser.

### 3.3.3 Val av features

När datan var granskad och genererade features framtagna, beslutades vilka features som var värda att arbeta vidare med för klassificering av byggnadsparametrarna från tabell 3.5. För prediktion övervägdes de features som finns representerade i tabell 3.6 och 3.7.

Valet gjordes genom att de figurer som beskrevs i avsnitt 3.2 studerades. Ett önskvärt scenario för en feature, som visualiseras på detta sätt, är att värden varierar inom olika intervall för de olika utfallen. Detta indikerar att det finns mönster i datan som kan skilja de olika utfallen åt. Exempel på ett önskvärt scenario presenteras i den vänstra delen av figur 3.3 som efterliknar exempelfigur 3.2. Högra delen av figuren visar ett scenario som inte är önskvärt där aktuell feature inte anses bidra med någon användbar information till maskininlärningsmodellen. I exempelfigur 3.3 skulle utfall 1 kunna representera *takutsprång* och utfall 2 *inte takutsprång* om det var takfot som studerades.



Figur 3.3: Exempel på boxplot. Önskvärt scenario till vänster, icke önskvärt till höger.

När features för byggnadskarakteristikerna valdes kombinerades ovan metod med en statistisk iterativ metod kallad *Stepwise regression*. Stepwise regression används för att finna de kombinationer av features som ger bäst utslag på det som ska predikteras. För byggnadskarakteristikerna övervägdes, utöver de features som beskrevs i tabell 3.6 och 3.7, även byggnadskategori som feature. Slutgiltigt valda features att använda i maskininlärningsprocessen, för både byggnadskategori och de olika byggnadskarakteristikerna, presenteras i tabell 3.8. Förkortningarna i tabellen förklarades i tabell 3.6 och 3.7.

Tabell 3.8: Features som valdes att arbeta vidare med.

| Byggnadsparameter             | Valda features                            |
|-------------------------------|---|
| Byggnadskategori              | Vån, År, AVA, TB, BA                      |
| Takfot                        | Kategori*, År, Vån, V/Ö, EP, TB           |
| Takform                       | Kategori, År, Vån, V/Ö, BA, TB            |
| Fasadmaterial                 | Kategori, V/Ö, S/N, LK, PN, EPC/fastighet |
| Takutsprång inte tegel        | Kategori, År, AB, TB, LK, PN              |
| * Kategori = Byggnadskategori |   |

### 3.4 Maskininlärningsmodeller - tillvägagångssätt vid generering

Efter att data var insamlad, bearbetad och intressanta features var valda utfördes modellering av maskininläring. Detta gjordes i programmeringsspråket R. De maskininlärningsmetoder som testades var:

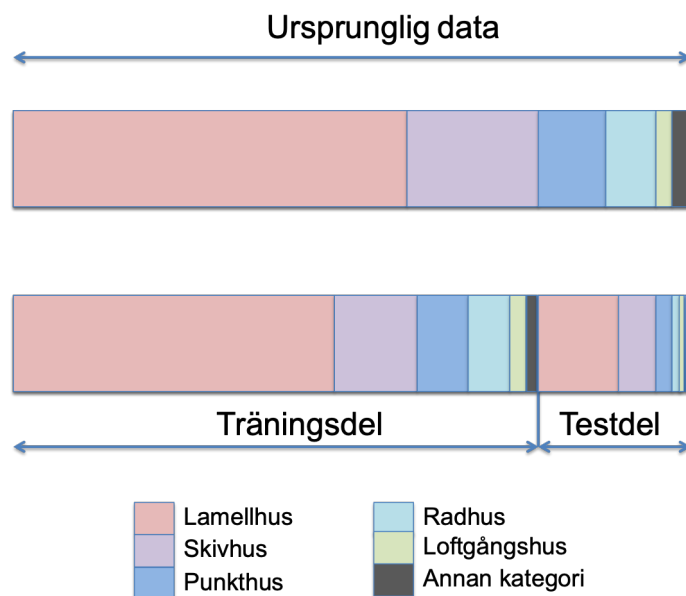
- o Logistisk Regression (LR)
- o Support Vector Machines (SVM)
- o Neurala Nätverk (NN)

Olika varianter av ovan metoder testades för att undersöka vilken modell som gav bäst träffsäkerhet för respektive byggnadsparameter. Analysen för att hitta den bästa modellen utfördes med en experimentell metodik där olika modeller testades med varierande sammansättningar av features för att slutligen hitta den optimala modellen. Optimal modell baseras på argumenten som presenteras senare i rapporten, se avsnitt 3.5.2.

För att kunna utföra analysen arbetades en metodik fram för modellering.

1. Det första som gjordes var att dela upp datasetet i två delar, en träningsdel och en testdel, se avsnitt 2.8.5. Träningsdelen bestod av 80% av datan medan testdelen bestod av resterande 20%. Vilken data som hamnade i respektive del skedde slumpvist. Uppdelningen på detta sätt skedde unikt för respektive byggnadsparameter som skulle predikteras.
2. Då fördelningen skedde slumpvis var det viktigt att kontrollera den procentuella fördelningen i

de olika dataseten. Fördelningen av varje utfall, för respektive byggnadsparameter, skulle vara ungefär lika i det ursprungliga datasetet, träningsdelen samt testdelen. Detta var extra viktigt i de fall där datan var ojämnt fördelad, med dominerande del lamellhus som exempel. Figur 3.4 är en exempelfigur som visar denna procentuella fördelning för byggnadskategori i de tre olika dataseten.



Figur 3.4: Procentuell fördelning av byggnadskategori för ursprungliga datasetet, tränings- och testdelen.

3. För att få robusta och mer stabila maskininlärningsmodeller normaliserades datan. Detta gjordes genom minmax-normalisering som beskrevs i avsnitt 2.8.3, ekvation 2.4.
4. Efter genomförande av punkt 1 till 3 utfördes den experimentella analysen. Varje maskininlärningsmodell testades med alla unika kombinationer av utvalda features, se tabell 3.8, som input. Detta resulterade i 26 unika kombinationer, se tabell 3.9, för byggnadskategorier. Ekvation 3.7 användes för att ta fram antalet unika kombinationer. För prediktion av respektive byggnadskaraktistik genererades 57 unika kombinationer med ekvation 3.8. Siffrorna 5 och 6 i ekvationerna kommer från att det för byggnadskategori fanns fem möjliga features att kombinera och för respektive byggnadskaraktistik fanns det sex.

$$\sum_{n=1}^5 \frac{5!}{n!(5-n)!} \quad (3.7)$$

$$\sum_{n=1}^6 \frac{6!}{n!(6-n)!} \quad (3.8)$$

### 3.4.1 Generering av modeller för logistisk regression

Följande tillvägagångssätt användes vid modellframtagning för varje byggnadsparameter från tabell 3.5:

1. Det befintliga paketet *Multinom*, som möjliggör analyser med logistisk regression, användes i R.
2. Samtliga kombinationer av features från tabell 3.8, för respektive byggnadsparameter, testades. Detta resulterade i 26 kombinationer för byggnadskategori och 57 kombinationer per byggnadskaraktäristik, enligt ekvation 3.7 och 3.8. Tabell 3.9 nedan visar de unika kombinationerna för byggnadskategori. Denna tabell presenteras för att läsaren ska förstå hur kombinationerna såg ut. Liknande tabeller genererades för samtliga byggnadskaraktäristiker med skillnaden att kombinationerna uppgick till 57 stycken.
3. För varje kombination av features utfördes ten fold cross validation, se avsnitt 2.8.8.
4. Den genomsnittliga träffsäkerheten från cross validation sparades för varje unik kombination från punkt 2.
5. Därefter tränades samtliga modeller om på träningssetet och predikterades på testsetet. Detta gjordes för varje unik kombination från punkt 2 för att få fram träffsäkerheten på ny osedd data.
6. De olika träffsäkerheterna, från punkt 4 och 5, jämfördes och utvärderades.

### 3.4.2 Generering av modeller för support vector machines

Följande tillvägagångssätt användes vid modellframtagning för varje byggnadsparameter från tabell 3.5:

1. Det befintliga paketet *svm*, som möjliggör analyser med support vector machines, användes i R.
2. Samma tillvägagångssätt som punkt 2 i 3.4.1.
3. För varje unik kombination från punkt 2 testades varierande värden på cost och gamma. Värden i spannet  $2^{-5:15}$  för cost respektive  $2^{-15:3}$  för gamma.
4. Ten fold cross validation utfördes för varje unik kombination från punkt 2, med cost och gamma enligt punkt 3. För den sammansättning av cost och gamma som genererade bäst träffsäkerhet sparades värdena på cost, gamma och träffsäkerheten.
5. Därefter tränades samtliga modeller från punkt 4, med optimala värden på cost och gamma, om på träningssetet och predikterades på testsetet. Detta gjordes för alla unika kombinationer från punkt 2 för att få fram träffsäkerheten på ny osedd data och möjliggöra jämförelse.

Tabell 3.9: Unika kombinationer av features för byggnadskategori.

| Unika kombinationer av features |     |     |    |    |
|---------------------------------|-----|-----|----|----|
| Vån                             | År  | -   | -  | -  |
| Vån                             | AVA | -   | -  | -  |
| Vån                             | BA  | -   | -  | -  |
| Vån                             | TB  | -   | -  | -  |
| År                              | AVA | -   | -  | -  |
| År                              | BA  | -   | -  | -  |
| År                              | TB  | -   | -  | -  |
| AVA                             | BA  | -   | -  | -  |
| AVA                             | TB  | -   | -  | -  |
| BA                              | TB  | -   | -  | -  |
| Vån                             | År  | AVA | -  | -  |
| Vån                             | År  | BA  | -  | -  |
| Vån                             | År  | TB  | -  | -  |
| Vån                             | AVA | BA  | -  | -  |
| Vån                             | AVA | TB  | -  | -  |
| Vån                             | BA  | TB  | -  | -  |
| År                              | AVA | BA  | -  | -  |
| År                              | AVA | TB  | -  | -  |
| År                              | BA  | TB  | -  | -  |
| AVA                             | BA  | TB  | -  | -  |
| Vån                             | År  | AVA | BA | -  |
| Vån                             | År  | AVA | TB | -  |
| Vån                             | År  | BA  | TB | -  |
| Vån                             | AVA | BA  | TB | -  |
| År                              | AVA | BA  | TB | -  |
| Vån                             | År  | AVA | BA | TB |


### 3.4.3 Generering av modeller för neurala nätverk

Tillvägagångssättet vid modellframtagning för neurala nätverk skiljde sig markant från tillvägagångssätten i avsnitt 3.4.1 och 3.4.2.


1. Efter att ha delat upp datasetet i en tränings- och en testdel, se punkt 1 i avsnitt 3.4, delades träningsdelen upp i ett provisoriskt träningsset och ett provisoriskt testset. Det nya träningssetet utgjorde 85% av den ursprungliga träningsdelen och 15% blev det nya testsetet.
2. Samtliga features, se tabell 3.8, för de olika byggnadsparametrarna användes vid modellframtagning av neurala nätverk.

3. Många strukturer på nätverket testades med olika antal dolda lager och noder. Antalet dolda lager varierades mellan ett till tre och antalet noder i varje lager mellan ett till fem. Exempelfigurer på hur nätverksstrukturer kunde se ut presenteras i figur 3.5 nedan. Totalt genererades och testades 155 strukturer per byggnadsparameter.
4. För varje struktur, från punkt 3, tränades modellen 30 gånger för att få ut den genomsnittliga träffsäkerheten på det provisoriska testsetet. Detta genomsnitt sparades.
5. Strukturerna analyserades och för ett, två respektive tre lager valdes de två bästa modellerna ut baserat på träffsäkerheten från punkt 4. Detta genererade sex modeller.
6. Samtliga modeller från punkt 5 tränades på den ursprungliga träningsdelen och testades på den ursprungliga testdelen. Detta gjordes tio gånger per modell och utfördes på grund av att de initiala viktningarna i nätverket varierade, vilket medförde ett flukturerande resultat. Det bästa resultatet för respektive modell, från punkt 5, sparades.


(a) Nätverkstruktur med ett dolt lager som innehåller en nod



(b) Nätverkstruktur med ett dolt lager som innehåller tre noder



(c) Nätverkstruktur med två dolda lager; ett med två noder och ett med tre noder



Figur 3.5: Exempel på genererade nätverksstrukturer.



## 3.5 Maskininlärningsmodeller - utvärdering och urval

Efter att de tre olika maskininlärningsmetoderna för prediktering av byggnadskategori, takfot, takform, fasadmateriäl och TET noggrant kodats och testats gjordes ett urval av vilka modeller som var optimala för respektive prediktion. De valda modellerna skulle senare komma att användas för att prediktera de olika utfallen på hela flerbostadshusbeståndet från de aktuella byggåren. För att välja de mest optimala modellerna gjordes flertalet avvägningar av vad som var önskvärt att modellerna skulle klara av. I avsnitt 3.5.2 nedan följer en bedömning av vad som var prioriterat för de maskininlärningsmodeller som skulle tas fram i just detta projekt.

### 3.5.1 Neurala nätverk exkluderas

Efter jämförelser med modeller från LR och SVM beslutades att inte arbeta vidare med modeller från NN-metoden. LR- och SVM-metoderna gav likvärdiga resultat, gick snabbare och var inte lika komplexa som NN-metoden. Dessutom medförde de slumpade initiala viktningarna, som beskrevs i punkt 6 i avsnitt 3.4.3, en osäkerhet.

### 3.5.2 Vad baseras urvalet på?

Följande argument låg gemensamt, utan inbördes ordning, till grund för valet av de optimala modellerna för respektive byggnadsparameter:

- Träffsäkerheten från cross validation, se avsnitt 2.8.8, granskades för modellerna med målet att hitta en modell med så hög träffsäkerhet som möjligt.
- Träffsäkerheten på testsetet skulle inte ha stora avvikelser från träffsäkerheten från cross validation.
- Träffsäkerheten på varje enskilt utfall noterades och det som skulle prioriteras vid aktuell prediktion togs i beaktning.
- Det undersöktes vart felen vid prediktion hamnade. Det vill säga när modellen predikterade fel, vad predikterade den istället? Detta kontrollerades med hjälp av en confusion matrix, se avsnitt 2.8.9.
- Antalet features i modellen togs i beaktning. Det vill säga en modell med färre antal features som presterade lika bra som en annan modell ansågs "simplare" och därav bättre.

Vid prediktion av byggnadskarakteristik togs även följande i beaktning:

- En modell som hade byggnadskategori som feature ansågs mer osäker än en annan modell som presterade lika bra men som inte innehöll byggnadskategori. Detta berodde på att byggnadskategori var predikterat och det var inte möjligt att med full säkerhet säga att värdet var korrekt.

### 3.5.3 Förenkling av modeller

För att förenkla de framtagna modellerna undersöktes när antal möjliga utfall för modellen kunde minimeras. Efter noggrann analys av renoveringspaketen, som presenterades i 2.6.3, beslutades att ändra antalet utfall för två modeller. Korrigering medförde följande:

- Möjliga utfall för fasadmaterial ändrades till antingen **tegel** eller **inte tegel**.
- Möjliga utfall för takform ändrades till antingen **fläktrum** eller **inte fläktrum**.

### 3.5.4 Slutgiltigt val av modeller

De bästa modellerna valdes baserat på resonemangen i avsnitt 3.5.2. I kommande avsnitt förklaras framtagningen av de valda modellerna för byggnadskategori, takform, fasadmaterial, takfot och TET.

#### 3.5.4.1 Byggnadskategori

Tillvägagångssättet vid val av modell för byggnadskategori förklaras nedan:

- Den bästa modellen för SVM respektive LR, baserat på träffsäkerheten från cross validation, togs med i urvalet för den optimala modellen.
- Utöver dessa valdes ytterligare två modeller ut baserat på att de hade jämnast fördelning mellan de olika byggnadskategorierna samt fortfarande erhöll en hög träffsäkerhet totalt.

Tabell 3.10 visar de modeller som togs fram till slutgiltigt urval. SVM1 och LR1 motsvarar de modeller med högst träffsäkerhet från cross validation medan SVM2 och LR2 hade en jämnare fördelning mellan de olika byggnadskategorierna, i förhållande till övriga modeller som togs fram i arbetet. Modellerna SVM1 och SVM2 byggs upp av fyra features vardera. Skillnaden mellan modellerna är att de består av olika sammansättning av features samt olika värden på inställningsparametrarna cost och gamma. För modellerna LR1 och LR2 är antalet features tre stycken. Skillnaden mellan båda dessa modeller är endast sammansättningen av features.

Från tabell 3.10 framgår att samtliga modeller erhöll en hög träffsäkerhet både vad gäller cross validation och testset. Detta tyder på att modellerna är stabila och robusta. Utöver detta visar tabell 3.11 att modellerna har en relativt jämn fördelning av träffsäkerhet per byggnadskategori. Det slutgiltiga valet av maskininlärningsmodell föll på SVM2 då det ansågs generera det mest optimala utfallet av träffsäkerhet per byggnadskategori samt att den hade goda resultat på cross validation och testsetet.

Tabell 3.10: Cost, gamma, CV- och testträffsäkerhet för de fyra bästa ML-modellerna

| Modell | Features         | Cost | Gamma        | CV [%] | Test [%] |
|--------|------------------|------|--------------|--------|----------|
| SVM1   | Vån, År, AVA, TB | 0,5  | 0,25         | 89,3   | 87,9     |
| SVM2   | Vån, År, AVA, BA | 4096 | 0,0009765625 | 88,5   | 88,9     |
| LR1    | Vån, År, AVA     | -    | -            | 88,0   | 87,9     |
| LR2    | Vån, År, BA      | -    | -            | 87,5   | 87,9     |

Tabell 3.11: Träffsäkerhet per byggnadskategori för de fyra ML-modellerna.

| Modell | Annan kategori [%] | Lamellhus [%] | Punkthus [%] | Radhus [%] | Skivhus [%] |
|--------|--------------------|---------------|--------------|------------|-------------|
| SVM1   | 0                  | 98,4          | 71,4         | 57,1       | 88,9        |
| SVM2   | 0                  | 95,2          | 71,4         | 85,7       | 94,4        |
| LR1    | 0                  | 93,7          | 85,7         | 85,7       | 88,9        |
| LR2    | 0                  | 95,2          | 85,7         | 71,4       | 88,9        |

### 3.5.4.2 Byggnadskarakteristiker

Baserat på argumenten i avsnitt 3.5.2 utfördes val av modell för att prediktera byggnadskarakteristiker. Valda modeller för karakteristikerna: Takfot, takform, fasadmaterial och TET presenteras i tabellerna 3.12-3.15. De två högra kolumnerna i dessa tabeller förklarar träffsäkerheten för respektive utfall.

Tabell 3.12: Vald modell för prediktering av takfot.

| Modell | Features        | CV [%] | Test [%] | Takutsprång [%] | Inte takutsprång [%] |
|--------|-----------------|--------|----------|-----------------|----------------------|
| LR     | År, TB, PN, V/Ö | 66,9   | 67,8     | 60,0            | 74,0                 |

Tabell 3.13: Vald modell för prediktering av takform.

| Modell | Features     | Cost | Gamma | CV [%] | Test [%] | Fläktrum [%] | Inte Fläktrum [%] |
|--------|--------------|------|-------|--------|----------|--------------|-------------------|
| SVM    | Kategori, År | 16   | 0,5   | 89,8   | 93,4     | 80,0         | 96,1              |

Tabell 3.14: Vald modell för prediktering av fasadmaterial.

| Modell | Features      | Cost | Gamma | CV [%] | Test [%] | Tegel [%] | Inte tegel [%] |
|--------|---------------|------|-------|--------|----------|-----------|----------------|
| SVM    | Kategori, V/Ö | 8    | 2     | 69,3   | 67,8     | 60,0      | 72,7           |

Tabell 3.15: Vald modell för prediktering av TET.

| Modell | Features       | Cost | Gamma   | CV [%] | Test [%] | Ja [%] | Nej [%] |
|--------|----------------|------|---------|--------|----------|--------|---------|
| SVM    | År, AB, TB, LK | 2048 | 0,03125 | 69,8   | 72,5     | 75,0   | 71,8    |

### 3.6 Prediktion på det svenska flerbostadshusbeståndet

När byggnadsparameterna skulle predikteras på samtliga byggnader i beståndet användes de framtagna maskininlärningsmodellerna som presenterades i avsnitt 3.5.4.1 och 3.5.4.2. Det stora datasetet, innehållandes 48 524 EPC:er, normaliserades på motsvarande sätt som för normaliseringen av tränings- och testdatan. Ekvation 2.4 användes med korrigeringen att max- och minimumvärden från träningsdatan, det lilla datasetet, användes istället för max- och minimum från den nya datan i det stora datasetet.

Vid prediktion av *byggnadskategori* plockades datapunkter bort efter normalisering. Detta gjordes när värden för någon feature avvek mer än 20% från träningsdatans max- och minimumvärden. SVM2-modellen från tabell 3.10 användes för prediktion. Däremot efter normalisering för prediktion av *takfot* respektive *TET* uteslöts byggnader där värden ansågs skilja för mycket från träningsdatan. Inför prediktionen av fasadmateriale och takform togs inga värden bort på grund av att alla värden låg inom acceptabelt intervall.

Det upptäcktes att en del byggnader i det stora datasetet hade antalet bostäder satt till noll. Detta ansågs indikera att dessa byggnader inte tillhör flerbostadshusbeståndet och prediktion uteblev. Detta berörde endast prediktion för TET, då antal bostäder användes som feature i detta fall. Resultatet i form av den procentuella fördelningen av byggnadsparametrar presenteras i kapitel 5, tabell 5.2-5.6. Uträkningarna för den procentuella fördelningen baserades på det totala antalet energideklarationer (EPC:er) i flerbostadshusbeståndet respektive total uppvärmd area (*Atemp*) i detsamma. För byggnadskategori var radhusen inkluderade i beräkningarna medan de exkluderades för byggnadskaraktistikerna. Anledningen till detta diskuteras i avsnitt 6.1.6 i slutet av rapporten. Värden som användes för beräkning av de procentuella fördelningarna återfinns i tabell 3.16-3.20 och beräknades enligt ekvation 3.9 och 3.10.

$$\text{Procent antal EPC:er per utfall} = \frac{\text{Antal EPC:er per utfall}}{\text{Totalt antal EPC:er i beståndet}} \quad (3.9)$$

$$\text{Procent Atemp per utfall} = \frac{\text{Total Atemp per utfall}}{\text{Totalt Atemp för beståndet}} \quad (3.10)$$

Tabell 3.16: Fördelningen av byggnadskategori på det svenska flerbostadshusbeståndet.

| Byggnadskategori            | Antal EPC:er [st] | Total Atemp [10 000 m <sup>2</sup> ] |
|-----------------------------|-------------------|--------------------------------------|
| Lamellhus                   | 38 552            | 7 272                                |
| Skivhus                     | 3 355             | 1 953                                |
| Punkthus                    | 2 074             | 816                                  |
| Radhus                      | 4 128             | 254                                  |
| Annan kategori              | 156               | 73                                   |
| Ej möjlig att prediktera    | 259               | 169                                  |
| <b>Totalt för beståndet</b> | <b>48 524</b>     | <b>10 537</b>                        |

Tabell 3.17: Fördelningen av takfot på det svenska flerbostadshusbeståndet, kategorin radhus exkluderad.

| Takfot                      | Antal EPC:er [st] | Total Atemp [10 000 m <sup>2</sup> ] |
|-----------------------------|-------------------|--------------------------------------|
| Takutsprång                 | 23 613            | 4 120                                |
| Inte takutsprång            | 18 320            | 5 710                                |
| Ej möjlig att prediktera    | 2 463             | 453                                  |
| <b>Totalt för beståndet</b> | 44 396            | 10 284                               |

Tabell 3.18: Fördelningen av takform i flerbostadshusbeståndet, kategorin radhus exkluderad.

| Takform                     | Antal EPC:er [st] | Total Atemp [10 000 m <sup>2</sup> ] |
|-----------------------------|-------------------|--------------------------------------|
| Fläktrum                    | 3 924             | 2 190                                |
| Inte fläktrum               | 40 213            | 7 925                                |
| Ej möjlig att prediktera    | 259               | 169                                  |
| <b>Totalt för beståndet</b> | 44 396            | 10 284                               |

Tabell 3.19: Fördelningen av fasadmateriäl i flerbostadshusbeståndet, kategorin radhus exkluderad.

| Fasadmateriäl               | Antal EPC:er [st] | Total Atemp [10 000 m <sup>2</sup> ] |
|-----------------------------|-------------------|--------------------------------------|
| Tegel                       | 17 087            | 3 735                                |
| Inte tegel                  | 26 800            | 6 320                                |
| Ej möjlig att prediktera    | 509               | 229                                  |
| <b>Totalt för beståndet</b> | 44 396            | 10 284                               |

Tabell 3.20: Fördelningen av TET i flerbostadshusbeståndet, kategorin radhus exkluderad.

| TET                         | Antal EPC:er [st] | Total Atemp [10 000 m <sup>2</sup> ] |
|-----------------------------|-------------------|--------------------------------------|
| Ja                          | 17 167            | 3 288                                |
| Nej                         | 26 916            | 6 955                                |
| Ej möjlig att prediktera    | 313               | 41                                   |
| <b>Totalt för beståndet</b> | 44 396            | 10 284                               |

### 3.6.1 Validering av prediktion

Efter att prediktionen var avklarade utfördes en validering av resultatet. Målet med denna validering var att kontrollera att modellen presterade utefter den träffsäkerhet som tidigare presenterats, se tabell 3.10-3.15. 20 stycken slumpmässigt utvalda byggnader observerades via Google maps. Byggnadstyp samt karakteristik noterades och jämfördes med det som modellen predikterade för den aktuella byggnaden.

## Kapitel 4

# Framtagning av energibesparande renoveringsplaner

*Detta kapitel behandlar generering av förslag på olika renoveringsplaner. Kapitlet inleds med framtagning följt av en förklaring hur energi- och kostnadsberäkningar utförts i projektet. Då samtliga beräkningar i detta kapitel utgår från studien Saga eller verklighet [2], se avsnitt 2.6.3, kommer denna studie genomgående i detta kapitel benämnas: SEV.*

### 4.1 Renoveringsplaner

Efter att samtliga byggnadsparametrar predikterats på det svenska flerbostadshusbeståndet kunde arbetet med att ta fram olika energibesparande renoveringsplaner påbörjas. Utgångspunkten för att ta fram renoveringsplanerna var de renoveringspaket (paket 1, paket 2 och paket 3) som presenterades i SEV. Olika renoveringsplaner genererades för att kunna jämföra dem med varandra.

De första renoveringsplanerna som genererades var två extremfall. Det första extremfallet var att enbart utföra paket 1 på samtliga byggnader i beståndet. Det andra extremfallet var istället att enbart utföra paket 3 på samtliga byggnader.

Efter att de två extremfallen genererats diskuterades vidare hur andra potentiella renoveringsplaner skulle kunna se ut. Med de tre renoveringspaketen, från SEV, i åtanke gjordes indelningar av byggnaderna för att kunna avgöra vilka renoveringspaket som var möjliga att utföra på respektive hus. De parametrar som antogs vara av betydelse, när förslag på renoveringsplaner togs fram, var:

- Byggnadskategori
- Energiklass
- Takform
- Fasadmaterial
- Byggår

Med denna information kunde grupperingar göras. Energiklass förklarades i avsnitt 2.4.1 och de byggnader som prioriterades att utföra energibesparande renovering på, var de som klassats som mer energikrävande på skalan. Det vill säga byggnader försedda med energiklass E-G.

Utöver detta gjordes avvägningar att det enbart är lämpligt att utföra tilläggsisolering av vindsbjälklagen, vilket ingår i paket 2, för de byggnader som inte är försedda med fläktrum. Därför blev detta också en faktor som togs hänsyn till vid generering av olika renoveringsplaner.

Som tidigare nämnts, i avsnitt 3.1.4, är det vid tilläggsisolering på ytterväggar, som ingår i paket 3, fördelaktigt om byggnaden har takutsprång och inte tegelfasad. Detta medförde att parametern TET var betydande i genereringsarbetet. När prediktion gjordes att TET stämde för en byggnad var paket 3 möjligt och fördelaktigt ur en energibesparingssynpunkt.

Även byggår togs med i generering av förslag på renoveringsplaner. Detta var för att kunna göra en prioritering att åtgärda byggnader som var äldre och därför förväntades vara i behov av energibesparande renovering mer omgående och omfattande.

Efter hänsyn tagen till samtliga ovan nämnda parametrar genererades sju olika förslag på renoveringsplaner. Dessa presenteras i figur 5.1-5.7.

## 4.2 Erhållen energibesparing

Då beräkningar av energibesparing och kostnad utgick från SEV behövde hänsyn tas till hur indelningen av byggnadskategorier gjorts där. Utifrån tabell 2.1 framgår att indelningen av lamellhus och skivhus i SEV delades in i flera olika kategorier. Detta är en indelning av byggnadskategorier som skiljer sig från indelningen i detta projekt. Dessutom uteblir radhus och *annan kategori* i SEV vilket medför att det inte finns något beräkningsunderlag för dessa byggnadskategorier. Detta medförde justeringar inför att energi- och kostnadsberäkningar skulle utföras. De förändringar som behövde göras var att:

- Lamellhusen i det stora datasetet delades upp i två kategorier med hänsyn tagen till byggår:
  - Tidiga lamellhus från 1945-1960
  - Sena lamellhus från 1960-1975
- Radhus och *annan kategori* uteslöts i beräkningarna

För att kunna utvärdera de olika renoveringsplanerna beräknades energibesparing samt kostnad på ett liknande sätt som gjordes i SEV med dataunderlag från densamma. Tillvägagångssättet för att beräkna energibesparing för varje enskild renoveringsplan, i figur 5.1-5.7, förklaras nedan:

1. Information om den totala energianvändningen för hela beståndet hämtades från det stora datasetet.
2. Renoveringsplanerna i figur 5.1-5.7 tillämpades och varje byggnad åtgärdades med ett av de tre renoveringspaketen.
3. För varje enskild byggnad applicerades den procentuella energibesparing, som presenterades i tabell 2.2, för den byggnadskategori och det renoveringspaket som skulle utföras. Med denna information kunde energianvändning per Atemp efter åtgärd beräknas för varje enskild byggnad.
4. Med hjälp av data från SEV beräknades andelen av den totala energin som utgjordes av fjärrvärme respektive el för varje byggnadskategori. I SEV förklarades procentuella förändring av elanvändning efter åtgärd jämfört med innan åtgärd. Samma procentuella förändring användes även i detta projekt. Andelen fjärrvärme efter energibesparande åtgärder beräknades sedan med ekvation 4.1 nedan.

$$E_{fv} = E_{total} - E_{el} \quad (4.1)$$

5. Energianvändning per Atemp, efter tillämpat renoveringspaket, för varje byggnad summerades. Detta resulterade i den totala energianvändningen per Atemp för hela beståndet efter att renovering utförts med aktuell renoveringsplan.
6. Total energibesparing för varje renoveringsplan kunde beräknas med ekvation 4.2 där  $E_1$  motsvarar energianvändningen per Atemp innan renovering för hela beståndet,  $E_2$  energianvändningen per Atemp efter renovering för hela beståndet och E den totala procentuella energibesparingen.

$$E = 1 - \frac{E_2}{E_1} \quad (4.2)$$



Den procentuella energibesparing, som applicerades i punkt 3 ovan, är direkt tagen från SEV. SEV innehåller endast en variant av punkthus och tidiga lamellhus, därav kunde procentuell energibesparing för punkthusen och de tidiga lamellhusen hämtas direkt från tabell 2.2. För de sena lamellhusen fanns det däremot två olika typer av byggnader i SEV som skulle överföras till en gemensam byggnadstyp, *lamellhus sena* i detta projekt. Detta utfördes genom att använda ett medelvärde från de två typbyggnaderna *lamellhus betong* och *lamellhus formgjuten* från SEV. Samma metodik, med ett beräknat medelvärde av *skivhus lättbetong* och *skivhus fasadelement*, användes för skivhusen.

### 4.3 Förväntad kostnad

För att utvärdera renoveringsplanerna i figur 5.1-5.7, räckte det inte med att endast veta energibesparingen. Kostnad var också en viktig aspekt att ta i beaktning. Den ekonomiska kalkylen strukturerades och beräknades baserat på det beräkningsunderlag som presenterades i SEV. Tillvägagångssättet presenteras nedan:

1. Den genomsnittliga arean ( $A_{temp}$ ) för varje byggnadskategori beräknades. Denna area jämfördes med arean på den typbyggnad som studien använt sig av. Kostnader från studien skalades om genom att använda den procentuella skillnaden mellan dessa två areor. Genom att utföra detta erhöles kostnader för varje genomsnittlig byggnad (lamellhus tidiga, lamellhus sena, skivhus och punkthus).
2. Grundinvesteringen beräknades genom att multiplicera kostnaderna, omskalade från punkt 1 kopplade till aktuellt renoveringspaket, med antalet byggnader som skulle tillämpas aktuellt paket för den byggnadskategorin. Antalet byggnader representeras av antalet energideklarationer i detta fall.
3. På motsvarande sätt som i punkt 2 beräknades underhållskostnader.
4. Grundinvesteringen för alla byggnadskategorier, med samtliga paket som skulle appliceras, summerades och resulterade i en gemensam grundinvestering för den aktuella renoveringsplanen.
5. Underhållskostnader summerades på motsvarande sätt som grundinvesteringen i punkt 4.
6. Genom att ta hänsyn till energibesparing, efter energibesparande åtgärder, kunde en årlig kostnadsreducering beräknas. Det vill säga hur mycket mindre kostar energin efter åtgärder i jämförelse med vad energin hade kostat om inga energibesparande åtgärder utförts. Denna årliga kostnadsreducering blev underlag för att beräkna återbetalningstid för de olika renoveringsplanerna.
6. Återbetalningstiden beräknades med ekvation 2.1 och grafer genererades för att visualisera investeringen. En känslighetsanalys utfördes för varje renoveringsplan genom att variera kalkylräntan för investeringen. Kalkylräntan som användes i beräkningarna var 0, 5 respektive 10%.

För att de olika renoveringsplanerna skulle kunna jämföras med varandra beräknades energibesparing per investerad krona. Detta beräknades med ekvation 4.3 och resultatet presenteras i tabell 5.8. Ekvationen och dess ingående variabler presenteras nedan:

$$y = \frac{E_{genomsnittlig} \cdot \frac{x_1}{100} \cdot Atemp \cdot 40}{x_2} \quad (4.3)$$

$x_1$  = Procentuell energibesparing för varje unik renoveringsplan

$x_2$  = Totalkostnad för grundinvestering samt alla årliga underhållskostnader under en 40 års-period för varje unik renoveringsplan

$E_{genomsnittlig} = 135.9 \frac{kWh}{m^2}$  = Den genomsnittliga energianvändningen per  $m^2$  ( $Atemp$ ) före reno-  
vering. Denna parameter är konstant för samtliga renoveringsplaner.

$Atemp = 1,03 \cdot 10^8 m^2$  = Den sammanlagda arean ( $Atemp$ ) för flerbostadshusbeståndet

$y$  = Energibesparing per investerad krona under en tidsperiod på 40 år.

# Kapitel 5

## Resultat

*Detta kapitel presenterar de slutliga resultaten från studien. Kapitlet är indelat i två delar. Den första delen behandlar resultaten som genererades från maskininlärningen och därmed prediktionen. Den andra delen presenterar de renoveringsplaner som tagits fram och även den känslighetsanalys som utvärderar investeringen som en renoveringsplan innebär.*

### 5.1 Maskininlärning - träffsäkerhet och prediktion

I detta projekt skulle klassificeringsproblem lösas med maskininlärning. Genom grundläggande utvärderingar av olika klassificeringsalgoritmer kunde optimerade modeller genereras.

#### 5.1.1 Genererade modeller och dess träffsäkerhet

Noggranna analyser resulterade i att SVM användes för byggnadsparametrarna: byggnadskategori, takform, fasadmaterial och TET. För takfot användes istället LR. Mer precist hur dessa modeller är uppbyggda presenterades i tabell 3.10-3.15. Träffsäkerheten på testdatan för samtliga modeller är sammanställda i tabell 5.1 nedan.

Tabell 5.1: Träffsäkerheten på testdatan, osedd data, för modellerna.

| <b>Byggnadsparameter</b> | <b>Maskininlärningsmodell</b> | <b>Träffsäkerhet [%]</b><br>Baserad på antal EPC:er |
|--------------------------|-------------------------------|---|
| Byggnadskategori         | SVM                           | 88,9  |
| Takfot                   | LR                            | 67,8  |
| Takform                  | SVM                           | 93,4  |
| Fasadmaterial            | SVM                           | 67,8  |
| TET                      | SVM                           | 72,5  |

### 5.1.2 Procentuell fördelning i det svenska flerbostadshusbeståndet

Resultatet från prediktion på det svenska flerbostadshusbeståndet presenteras i tabell 5.2-5.6 nedan. Den procentuella fördelningen indikerar hur stor andel av beståndet som utgörs av en specifik byggnadskategori och hur stora delar som är försedda med olika byggnadskaraktistiker. I samtliga tabeller återfinns ett utfall *Ej möjlig att prediktera*. Detta utfall är en samling av det som inte kunde predikteras av olika anledningar. Anledningarna var:

- att data saknades för de features som användes vid prediktionen
- att värdet för en feature hamnade utanför det intervall som var acceptabelt
- att antal bostäder var noll från inputdatan.

I tabell 5.2-5.6 nedan visar den vänstra kolumnen den procentuella fördelningen, baserad på antal energideklarationer, för respektive utfall. Den högra kolumnen visar fördelningen baserat på Atemp.

Tabell 5.2: Procentuell fördelning av byggnadskategorier från aktuell tidsperiod.

| Byggnadskategori         | Procentuell fördelning [%] |                  |
|--------------------------|----------------------------|------------------|
|                          | Baserad på antal EPC       | Baserad på Atemp |
| Lamellhus                | 79,4                       | 69,0             |
| Skivhus                  | 6,9                        | 18,5             |
| Punkthus                 | 4,3                        | 7,7              |
| Radhus                   | 8,5                        | 2,4              |
| Annan kategori           | 0,3                        | 0,7              |
| Ej möjlig att prediktera | 0,6                        | 1,6              |

Tabell 5.3: Procentuella fördelningen av takfot från aktuell tidsperiod.

| Takfot                   | Procentuell fördelning[%] |                  |
|--------------------------|---------------------------|------------------|
|                          | Baserad på antal EPC      | Baserad på Atemp |
| Takutsprång              | 53,2                      | 40,1             |
| Inte takutsprång         | 41,3                      | 55,5             |
| Ej möjlig att prediktera | 5,5                       | 4,4              |

Tabell 5.4: Procentuell fördelningen av fläktrum från aktuell tidsperiod.

| Takform                  | Procentuell fördelning [%] |                  |
|--------------------------|----------------------------|------------------|
|                          | Baserad på antal EPC       | Baserad på Atemp |
| Fläktrum                 | 8,8                        | 21,3             |
| Inte fläktrum            | 90,6                       | 77,1             |
| Ej möjlig att prediktera | 0,6                        | 1,6              |

Tabell 5.5: Procentuell fördelningen av tegelhus från aktuell tidsperiod.

| Fasadmaterial            | Procentuell fördelning [%] |                  |
|--------------------------|----------------------------|------------------|
|                          | Baserad på antal EPC       | Baserad på Atemp |
| Tegel                    | 38,5                       | 36,3             |
| Inte tegel               | 60,4                       | 61,5             |
| Ej möjlig att prediktera | 1,1                        | 2,2              |

Tabell 5.6: Procentuell fördelningen av TET från aktuell tidsperiod.

| TET                      | Procentuell fördelning [%] |                  |
|--------------------------|----------------------------|------------------|
|                          | Baserad på antal EPC       | Baserad på Atemp |
| Ja                       | 38,7                       | 32,0             |
| Nej                      | 60,6                       | 67,6             |
| Ej möjlig att prediktera | 0,7                        | 0,4              |

### 5.1.3 Validering av prediktion

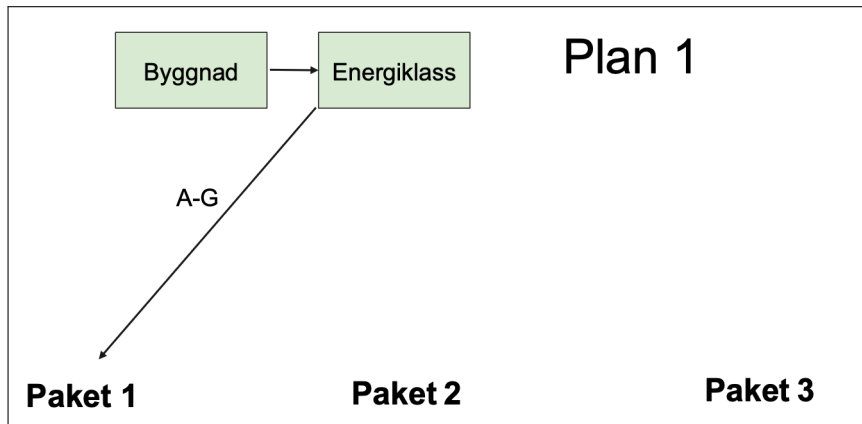
I detta avsnitt presenteras resultatet på valideringen från avsnitt 3.6.1 av maskininlärningsmodellerna. Tabell 5.7 visar träffsäkerheten från valideringen för prediktion av de olika byggnadsparametrarna. Värdena i denna tabell är jämförbara med värdena i tabell 5.1. Den nedre delen av tabell 5.7 visar träffsäkerheten när modellen för att prediktera takfot och fasadmaterial kombineras, det vill säga träffsäkerheten visar när båda modellerna predikterar korrekt samtidigt.

Tabell 5.7: Validering av resultatet från prediktionen på 20 slumpmässigt utvalda byggnader.

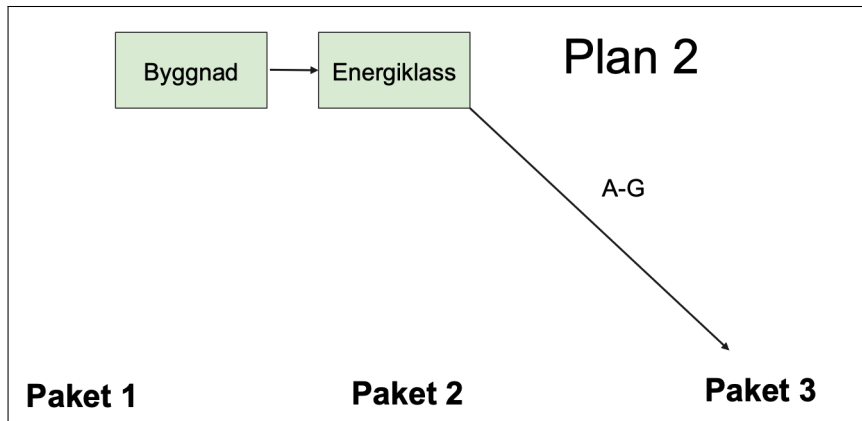
|  | Träffsäkerhet baserad på antal EPC:er [%] |
|--|---|
| Byggnadskategori   | 90,0                                      |
| Takfot   | 73,7                                      |
| Takform  | 89,5                                      |
| Fasadmaterial  | 57,9                                      |
| TET  | 63,2                                      |
| Kombination när prediktionen blir rätt för både takfot och fasadmaterial |   |
|  | Träffsäkerhet baserad på antal EPC [%]    |
| Takfot & Fasadmaterial   | 42,1                                      |

## 5.2 Renoveringsplaner - energibesparing och kostnad

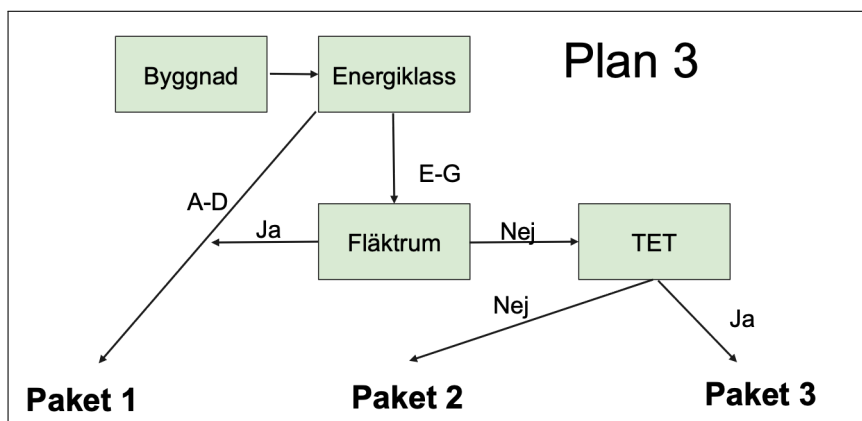
Nedan presenteras de energibesparande renoveringsplaner som genererades i avsnitt 4.1. Dessa visualiseras i figur 5.1-5.7. Detta är möjliga förslag på renoveringsplaner som kan ligga till grund för den uppdaterade renoveringsstrategin.



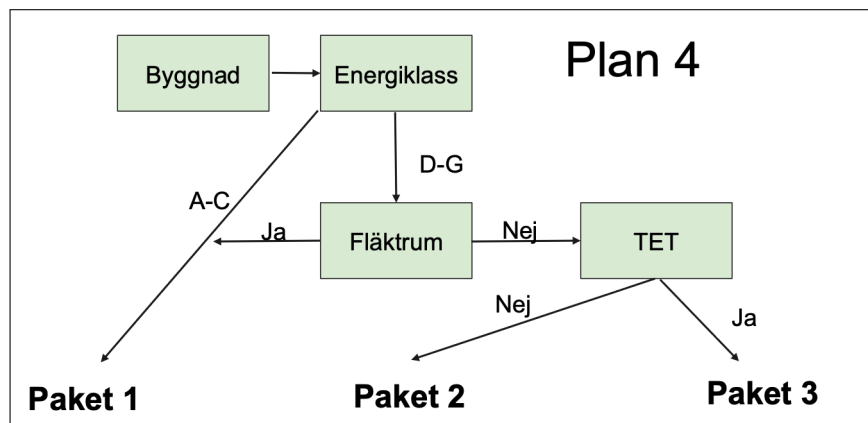
Figur 5.1: Paket 1 genomförs på hela flerbostadshusbeståndet.



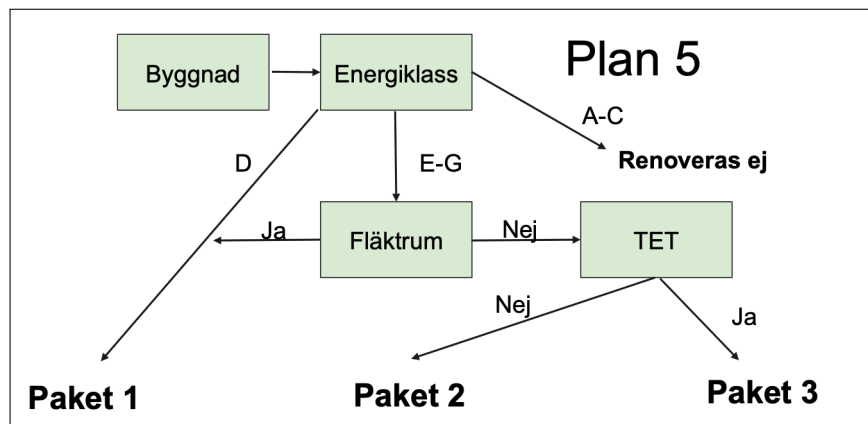
Figur 5.2: Paket 3 genomförs på hela flerbostadshusbeståndet.



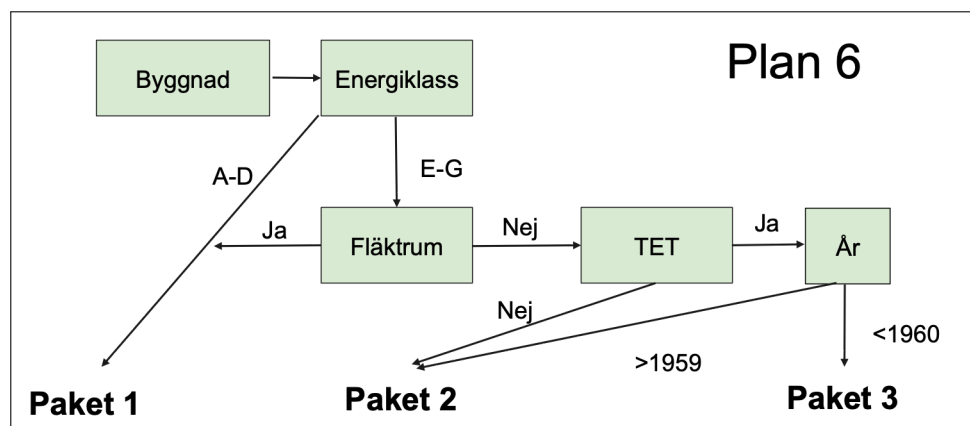
Figur 5.3: Renoveringspaket bestäms för varje byggnad baserat på energiklass, om takformen är fläktrum eller inte samt om byggnaden har takutsprång och inte tegelfasad.



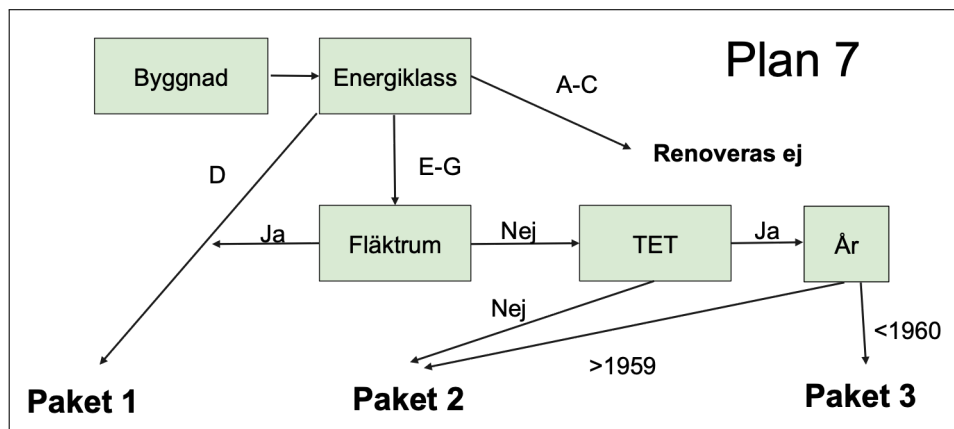
Figur 5.4: Liknande som i 5.3 med förändringen att energiklass D flyttas till höger i figuren.



Figur 5.5: Liknande som i figur 5.3 med förändringen att byggnader med energiklass A-C inte åtgärdas.




Figur 5.6: Ytterligare en variant av figur 5.3. För de byggnader som kvalificerar sig för paket 3 undersöks årtalet. Byggnader med byggår före 1960 tilldelas paket 3 och byggår efter 1960 tilldelas paket 2.



Figur 5.7: En kombination av renoveringsplan 5 och 6, se figur 5.5 och 5.6

I renoveringsplanerna fördelas byggnaderna, med hänsyn tagen till dess karakteristiker, till de tre renoveringspaketen paket 1, paket 2 eller paket 3 från *Saga eller verklighet* [2]. Utifrån *plan 3* till *plan 7*, av ovan energibesparande renoveringsplaner, i kombination med kunskap kring byggnadernas karakteristik som presenterades i tabell 5.2-5.6 har figur 5.8 genererats. I figuren visualiseras hur stor del av beståndet, från respektive byggnadskategori baserat på Atemp, som fördelas till vilket renoveringspaket för respektive framtagna renoveringsplan. De olika färgerna representerar varsin byggnadskategori och staplarna är kopplade till paket 1, paket 2 och paket 3.



Figur 5.8: Fördelning av byggnadskategori per renoveringspaket och renoveringsplan.




### 5.2.1 Energibesparing och kostnad

Genom beräkningar för respektive renoveringsplan kontrollerades hur stor energibesparing som kunde uppnås till vilken kostnad, se tabell 5.8. Kalkyler gjordes också för att förstå värdet, energibesparingen, av varje investerad krona. Kostnaden är uppdelad som en grundinvestering och en totalkostnad. Grundinvesteringen motsvarar vad en nyinstallation av alla energibesparande renoveringsåtgärder skulle innebära. Totalkostnad innefattar samtliga kostnader, relaterade till åtgärderna i renoveringsplanerna, som uppstår under 40 år. För att få en förståelse för vad varje renoveringsplan skulle innebära i energibesparing visualiseras detta i figur 5.9. Stapeln längst till vänster i figuren visar energianvändningen innan åtgärd. De övriga staplarna representerar energianvändningen efter att respektive renoveringsplan som presenterades i figur 5.1-5.7 tillämpats på flerbostadshusbeståndet.

Tabell 5.8: Energibesparing och kostnad med respektive renoveringsplan.


| Renoveringsplan | Energi-<br>besparing<br>[%] | Grund-<br>investering<br>[Miljarder kr] | Total-<br>kostnad 40 år<br>[Miljarder kr] | Energibesparing<br>per krona<br>[ $\frac{kWh}{kr}$ ] |
|-----------------|-----------------------------|---|---|--|
| Variabel        | $x_1$                       | -                                       | $x_2$                                     | $y$  |
| Plan 1          | 11,8                        | 5,4                                     | 8,5                                       | 7,7  |
| Plan 2          | 60,4                        | 103,4                                   | 118,6                                     | 2,8  |
| Plan 3          | 34,7                        | 49,1                                    | 58,3                                      | 3,3  |
| Plan 4          | 37,5                        | 56,9                                    | 67,1                                      | 3,1  |
| Plan 5          | 34,5                        | 49,0                                    | 58,0                                      | 3,3  |
| Plan 6          | 31,4                        | 45,6                                    | 54,3                                      | 3,2  |
| Plan 7          | 31,2                        | 45,5                                    | 54,1                                      | 3,2  |



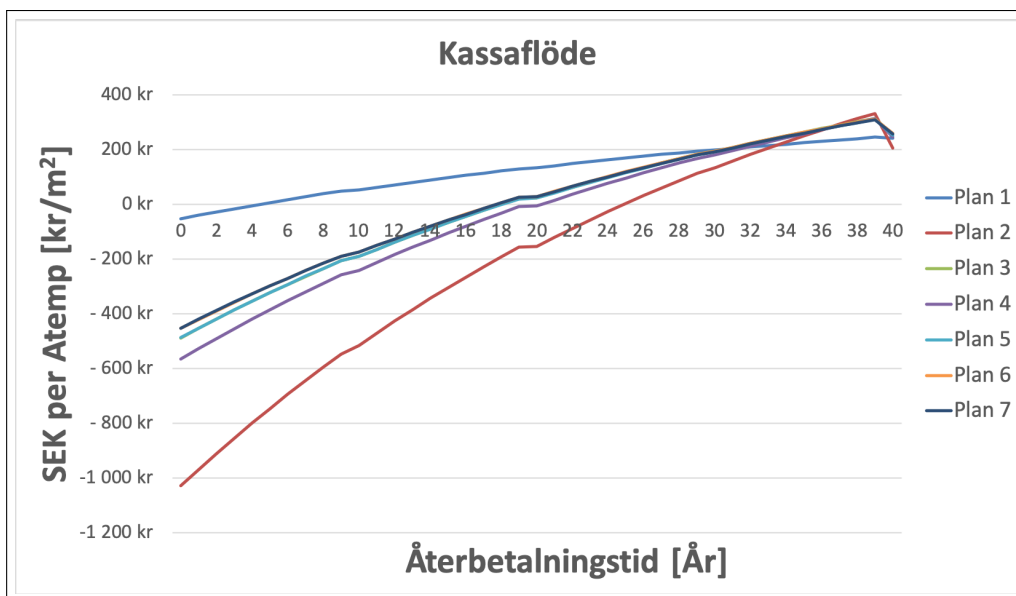
Figur 5.9: Energianvändning, efter åtgärd, per renoveringsplan.

### 5.2.2 Känslighetsanalys


Känslighetsanalysen som utfördes, se punkt 6 i avsnitt 4.3, presenteras i figur 5.10-5.12. Figurerna visar bland annat återbetalningstiden för de olika planerna från figur 5.1-5.7. När en kurva skär x-axeln innebär det att renoveringsplanens grundinvestering har slagits ut av den avtagande årliga kostnaden tack vare energibesparingen. Skillnaden i figur 5.10-5.12 är att kalkylräntan har antagit 0, 5 respektive 10%.



Figur 5.10: Ekonomisk kalkyl med kalkylräntan satt till 0%.



Figur 5.11: Ekonomisk kalkyl med kalkylräntan satt till 5%.



Figur 5.12: Ekonomisk kalkyl med kalkylräntan satt till 10%.

# Kapitel 6

## Diskussion

*I detta kapitel diskuteras de beslut, antaganden och resonemang som uppstått under arbetets gång. Avsikten med detta är att ge läsaren bättre förståelse för de delmoment som lett till vidare arbete i processen och förstå resultaten i ett större sammanhang. Först diskuteras den metod som berör maskininlärning från kapitel 3. Metodiken som användes för modellering var komplex och innefattade många steg som byggde vidare på varandra. Därefter följer ett avsnitt med en diskussion kring de renoveringsplaner som togs fram i kapitel 4. Avslutningsvis förklaras hur resultaten bidrar till att uppfylla syftet med studien.*

### 6.1 Maskininlärning - resonemang och förtydligande

#### 6.1.1 Datahantering - att lära känna data

Anledningen till att observationerna i avsnitt 3.1 gjordes med hjälp av Google maps istället för att fysiskt besöka byggnaderna för observation berodde på att det var tidseffektivt och lämpade sig väl för detta relativt tidsbegränsade projekt. Detta tillvägagångssätt var en förutsättning för genomförandet av projektet.

Som presenterades i avsnitt 2.7.2 genererade forskargruppen på RISE adresserna i det lilla datasetet baserat på Atemp vilket medförde att datan var överrepresenterad av stora byggnader. Anledningen var att de ville försäkra sig om att det lilla datasetet innehöll flertalet stora byggnader. Med stora byggnader tillgängliga i datan, som används för skapandet av maskininlärningsmodellen, så är också chansen större att modellen blir bra på att känna igen stora hus. Om maskininlärningsmodellen kan klassificera de större byggnaderna på ett tillförlitligt sätt blir resultatet mer tillförlitligt och energibesparingen blir större än om modellen istället var bra på att klassificera mindre byggnader. Detta medför ett litet problem i form av att den procentuella fördelningen av stora byggnader i det genererade datasetet skiljer sig från den procentuella andelen stora byggnader efter prediktion på det svenska flerbostadshusbeståndet.

I avsnitt 3.1.6 presenterades de features som genererades i projektet. Tanken bakom dessa features var:

**Atemp per våning**, ekvation 3.1, genererades med idén att kunna skilja på byggnader baserat på arean per våningsplan. Förväntningarna var att exempelvis lamellhus och skivhus skulle erhålla ett högt värde medan exempelvis punkthus och radhus skulle erhålla ett lägre värde.

**Bostäder per adress**, ekvation 3.2, skapades för att kunna skilja punkthusen från övriga. Tanken var att i ett punkthus finns det många bostäder samtidigt som det endast finns en trappuppgång och endast en ingång på bottenplan. Detta innebär många olika bostäder på endast en adress. För radhus däremot så bör värdet bli 1 på grund av att för ett radhus tillhör varje enskild bostad en egen adress. För lamellhus och skivhus bör värdet hamna mellan det för radhusen och punkthusen.

**Trapphus per adress**, ekvation 3.3, antogs bli 1 för punkthusen, 0 för radhusen och ett högre värde för lamellhusen och skivhusen.

**Atemp per våning per adress**, ekvation 3.4, skapades som en utveckling av Atemp per våning. Syftet med denna parameter var samma som för Atemp per våning, men hänsyn togs till att vissa energideklarationer innehöll deklaration för flera adresser. Denna korrigering tog hänsyn till de fall där antalet adresser var flera stycken.

**Atemp per våning per trapphus**, ekvation 3.5, skapades som en utveckling av Atemp per våning. Tanken var även här att ta hänsyn till att datan från energideklarationen i vissa fall motsvarade flera adresser. Se förklaring för Atemp per våning per adress för en utförligare förklaring.

**Antal trapphus per bostad**, se ekvation 3.6, genererades med tanken att skilja mellan en högre och en lägre byggnad. I en högre byggnad finns det i regel fler bostäder på lika många trappuppgångar. Idén var att skilja på byggnadskategorier genom att:

- **Radhus** antar värdet noll eftersom antalet trapphus bör vara noll.
- **Punkthus** är en hög byggnad med många bostäder. Det borde implicera ett lågt värde för denna feature.
- **Skivhus** är också en hög byggnad men har i regel fler trapphus än vad punkthus har. Detta implicerar ett något högre värde än för punkthusen.
- **Lamellhus** är en lägre byggnad med färre bostäder på flera trappuppgångar. Detta implicerar ett högre värde på denna feature.

### 6.1.2 Visualisering - metodik för att finna mönster

Anledningen till att datan visualiserades var för att underlätta förståelsen för vad olika features bidrog med för mönster till maskininlärningsmodellen. Skapandet av figurer likt 3.1 användes för att visualisera hur de olika byggnadskategorierna förhöll sig till olika features men framförallt för att öka förståelsen för datan.

Boxplottarna, se figur 3.2, användes för att kunna avgöra hur features varierade för varje enskild byggnadsparameter. Att använda boxplots på detta sätt gav underlag för att antingen ta bort någon feature eller fokusera ytterligare på någon annan. Om en feature inte varierade speciellt mycket kunde slutsatser dras att denna feature inte hade speciellt stor påverkan för att avgöra vilket utfall av byggnadsparametrarna det handlade om i slutändan. En feature som däremot varierade mycket, och där spannet för variation skiljde sig mellan olika utfall, kunde innebära att denna feature var lämplig för att skilja de olika utfallen för byggnadsparametrarna åt.

### 6.1.3 Dataförberedning - möjliggör maskininlärning

Valet med att kategorisera om och på så sätt inte gå vidare med loftgångshusen, som beskrevs i avsnitt 3.3.1, baserades framförallt på tre argument.

- Det fanns för få datapunkter i urvalet på de 500 adresserna som var kategoriserade som loftgångshus.
- Utöver det gick det inte att hitta något tydligt mönster bland loftgångshusen. Dessa två anledningar skulle tillsammans medföra att maskininlärningsmodellen skulle få problem att i framtiden kunna prediktera denna byggnadskategori. Modellen skulle bli mer effektiv om loftgångshusen inte var en egen kategori i datan.
- Ytterligare ett argument till varför det ansågs vara befogat att kategorisera om loftgångshusen var att renoveringsåtgärderna på denna byggnadskategori inte skulle skilja sig särskilt mycket åt från om byggnaden ansågs vara ett lamellhus eller skivhus istället. Om åtgärderna ändå inte skulle skiljas åt skulle beräkningarna bli de samma. Kostnad och energibesparing för ett hus som till utseendet såg ut som ett loftgångshus men som kategoriserats om till ett lamellhus skulle bli oförändrade.

Slutsatsen är att maskininlärningsmodellen genererade ett renare mönster, och blev på så sätt mer optimerad, när loftgångshusen var omkategoriserade. Ingen förändring skulle ske för de energibesparande renoveringsåtgärderna vilket ej påverkar slutresultatet.

### 6.1.4 Maskininlärningsmodeller - tillvägagångssätt vid generering

I projektet testades tre olika maskininlärningsmetoder, LR, SVM och NN, som beskrevs i avsnitt 2.8.2. Anledningen till att just dessa tre metoder testades grundade sig i att de är vanligt förekommande maskininlärningsmetoder för klassificeringsproblem. Detta kombinerat med att författarna var bekanta med metoderna sedan tidigare och att de hade sett metoderna användas, i liknande sammanhang, tidigare

styrkte argumenten till varför just dessa metoder skulle användas i detta projekt. Orsaken till varför inte fler metoder valdes att testas berodde på att resultaten blev tillräckligt bra för de testade metoderna från början samt att projektets tidsomfattning var begränsad. Utöver detta var maskininlärningsmetoderna relativt enkla att använda och det förväntades underlätta om en liknande undersökning skulle utföras i framtiden utifrån tillvägagångssättet i detta projekt.

Vid användandet av LR och SVM skapades flertalet modeller med många olika unika kombinationer av features, se tabell 3.9 för exempel. Detta gjordes för att testa och utvärdera vilka kombinationer av features som gav upphov till en bra modell. Förväntningar skulle kunna vara att fler features resulterar i en bättre modell men så är inte alltid fallet. Genom att testa samtliga unika kombinationer av features går det att säkerställa att den modell som väljs i slutändan har den mest optimala sammansättningen av features. När denna metod utfördes upptäcktes att en modell med två features absolut kan konkurrera ut en modell med exempelvis fyra features.

Indelningen av datasetet i en tränings- och en testdel, som beskrevs i avsnitt 2.8.5, gjordes separat för varje enskild byggnadsparameter som skulle predikteras. Modellerna för respektive byggnadsparameter tränades och utvärderades alltså med olika test- och träningsset. Detta medförde inga problem i projektet då modellerna inte skulle jämföras sinsemellan. De modeller som jämfördes var enbart de modeller som predikterade en gemensam byggnadsparameter. Det vill säga, de modeller som genererades för att prediktera till exempel byggnadskategori jämfördes med övriga modeller som predikterade byggnadskategori för att hitta den mest optimala modellen för just den byggnadsparametern. På samma sätt jämfördes modellerna separat för de övriga byggnadsparametrarna för att få ut optimala modeller per karakteristik.

En jämförelse gjordes dock mellan de modeller som predikterade takfot, fasadmateriel och TET. Här gjordes en jämförelse för att förstå om det var mer effektivt att använda modellerna för takfot och fasadmateriel tillsammans eller om de vore bättre att använda enbart modellen för TET för att prediktera ”takfot ej tegel”. När denna jämförelse gjordes hade det varit bättre om dessa modeller hade utgått och tränats på samma tränings- och testset för att få en mer korrekt jämförelse, vilket inte gjordes i detta projekt.

Anledningen till att tränings- och testdelarna delades upp på varierande sätt för de olika byggnadsparametrarna berodde i huvudsak på att den procentuella kontrollen, som beskrevs under punkt 2 i avsnitt 3.4, skulle göras för respektive parameter som skulle predikteras. Exempelvis var det önskvärt att det skulle finnas lika stor andel lamellhus i både tränings- och testdelen för att ha balanserade dataset. Det samma gällde för de övriga byggnadsparametrarna. Det var exempelvis viktigt att det var lika många tak med, och utan, takutsprång i tränings- och testdelen när takfot skulle predikteras.

### 6.1.5 Maskininlärningsmodeller - utvärdering och urval

Det föll sig naturligt att maskininlärningsmodellerna som baserades på NN-metoden valdes bort tidigt i detta projekt. Detta grundade sig framförallt i att NN-modellerna tog betydligt längre tid att träna än vad det gjorde att träna modeller med LR- och SVM-metoderna. Tidsfördröjningen var inte speciellt lämplig

för det såpass tidsbegränsade arbete som detta projekt faktiskt var. Dessutom genereras ungefär samma resultat från NN-modellerna som för övriga modeller. Detta innebar att det var befogat att välja någon av de genererade LR- eller SVM-modellerna för prediktering istället. Utöver tids- och resultatasppekterna som argument för att välja bort NN i vidare arbete ansågs metoden dessutom vara för komplicerad för omfattningen av detta projekt. Komplexiteten innebar att det var svårt att se och förstå alla steg som innefattades i NN-modellerna, vilket gav en oönskad osäkerhet.

När maskininlärningsmodellerna valdes för de olika byggnadsparametrarna var det viktigt att kontrollera att träffsäkerheten på cross validation och testsetet var likvärdiga. Denna kontroll var betydande för att försäkra att en modell inte gav dålig träffsäkerhet på exempelvis cross validation men bra träffsäkerhet på testsetet. I sådana fall skulle det betyda att testsetet var utvalt på ett sätt som var gynnsamt för just den modellen och att den höga träffsäkerheten berodde på tur istället för en optimerad modell. En kontroll mellan likvärdigheten av träffsäkerheten för cross validation och testsetet ökade alltså trovärdigheten för modellen. När dessa två värden var ungefär samma indikerade detta att modellen var stabil och robust.

I avsnitt 3.5.4.1 beskrevs hur den optimala modellen för byggnadskategori valdes. I avsnittet framgår att den SVM-modell som genererade högst träffsäkerhet på cross validation samt hög träffsäkerhet på lamellhusen, SVM1 från tabell 3.10, inte valdes till den optimala modellen. Detta berodde på att den modellen inte enbart predikterade lamellhus som lamellhus. Modellen predikterade även hus från samtliga andra byggnadskategorier som lamellhus. Detta innebar bland annat att exempelvis ett skivhus kunde predikteras som ett lamellhus. Detta var inte önskvärt då många felbedömningar skulle ha gjorts angående vilka byggnadskategorier som skulle kräva renovering. Anledningen till att inte välja denna modell som den optimala var alltså problematiken kring att "för många" hus skulle ha blivit kategoriserade som lamellhus i det svenska flerbostadshusbeståndet. Utöver detta hade modellen också en dålig träffsäkerhet på radhusen. Detta var inte heller önskvärt, då det var viktigt att radhusen skulle hittas i det stora datasetet för att de senare plockas bort när renoveringsplaner skulle genereras och energibesparing beräknas.

Två maskininlärningsmodeller förenklades under arbetets gång. Förenklingarna gjordes för modellen som predikterade fasadmaterial respektive takform vilket beskrevs i avsnitt 3.5.3. Orsaken till att justeringar gjordes var på grund av att dessa modeller hade problem att känna igen alla karakteristiker som skulle predikteras. Exempelvis hade modellen för fasadmaterial svårt att känna igen träfasader, plåtfasader samt fasader med betongelement. Modellen för takform hade problem att känna igen pulpettak och platta tak. Istället för att ha så specifika indelningar av de olika utfallen ansågs det viktigare att kunna avgöra om det var ett tegelhus eller inte respektive om taket var försett med fläktrum eller inte. Därav beslutades att förenkla dessa modeller för att kunna ge förslag på lämpliga renoveringsplaner med ingående renoveringspaket som kräver vissa specifika karakteristiker hos byggnaderna.

För att vidare förstå vikten av det utvärderingsarbete som utfördes för maskininlärningsmodellerna är det intressant att analysera den framtagna byggnadsparametern TET. Anledningen till att modeller för denna parameter användes istället för att använda modeller för både fasadmaterial och takform var för att TET gav en mer tillförlitlig träffsäkerhet. Enligt tabell 5.1 är träffsäkerheten för TET 72,5% medan den



för fasadmaterial respektive takfot är 67,8% vardera. Dessutom uppstår en osäkerhet när fasadmaterial och takfot predikteras med två olika modeller för att sedan sammanföra resultatet. Trots att modellerna har en träffsäkerhet på 67,8% vardera, betyder inte det att modellerna predikterar rätt samtidigt och på samma datapunkt. Det vill säga, om man vill prediktera om en byggnad har takutsprång och ej tegelfasad så kanske en av modellerna gör rätt samtidigt som den andra gör fel vid just det tillfället. Detta innebär att kombinationen av takfot och fasadmaterial inte kommer nå upp till en träffsäkerhet på 67,8%. Detta fenomen kan noteras längst ner i validering av resultatet, se tabell 5.7. Detta medförde att valet att använda TET var självklart.

### 6.1.6 Prediktion på det svenska flerbostadshusbeståndet

Som går att läsa i avsnitt 3.6 normaliserades det stora datasetet med max- och minimumvärden från modellens träningsdata. Detta gjordes för att säkerställa att värden från det stora datasetet förekom inom samma intervall som för träningsdatan. För de värden som, efter normalisering, antog ett värde större än 1 eller mindre än 0 innebar att dessa värden låg utanför modellens tränade intervall. Detta innebar att det kunde bli en större osäkerhet eftersom modellen förväntades prediktera på data i ett intervall som den inte sett tidigare. Om det hade varit många värden, efter normalisering, som hamnade utanför de normaliserade värdena från träningsdatan så hade det betytt att det lilla dataset inte var representativt för det svenska flerbostadshusbeståndet. Detta var som tur inte fallet, utan de flesta värdena hamnade inom rätt intervall och de 500 adresserna som det utfördes observation på, kunde antas vara en ganska bra fingervisning på hur det svenska flerbostadshusbeståndet ser ut.

De genererade maskininlärningsmodellerna, se tabell 3.10-3.15, utvärderades och testades på testdata vars värden är normaliserade efter testdatans min- och maximumvärden. För att få en mer korrekt analys borde testdatan ha normaliserats på träningsdatans värden. Orsaken till att detta inte korrigerades var att detta upptäcktes för sent in processen för projektet.

I avsnitt 6.1.1 diskuterades att urvalet av de 500 adresser som observerades, se avsnitt 2.7.2, var överrepresenterade av stora hus. Detta bekräftades efter prediktion av byggnaderna på det svenska flerbostadshusbeståndet. Vid prediktion erhöles en lägre andel skivhus än vad som fanns tillgängligt i de 500 adresserna som observerades. Skivhus har i regel en stor area (Atemp), vilket indikerar att en större andel skivhus bland de 500 adresserna innebär överrepresentation av stora byggnader i urvalet.

Vid prediktion av de olika byggnadskarakteristikerna togs radhusen bort på grund av att de inte utgör en del av flerbostadshusbeståndet som denna studie undersöker. Anledningen till att radhusen fanns med vid prediktionen av byggnadskategori var för att de utgjorde en del av dataunderlaget. Radhusen behövde predikteras för att senare kunna plockas bort när byggnadskarakteristikerna skulle predikteras.

## 6.2 Renoveringsplaner - bakomliggande tankar

De olika renoveringsplaner som togs fram i avsnitt 4.1 och presenteras i resultatdelen som figurer, se avsnitt 5.2, diskuteras kortfattat nedan:

**Renoveringsplan 1**, figur 5.1, innebär att paket 1 utförs på hela beståndet. Paket 1 är enkelt och billigt att genomföra och skulle kunna ses som minsta möjliga åtgärd ur ett energibesparingsperspektiv.

**Renoveringsplan 2**, figur 5.2, innebär att paket 3 utförs på hela beståndet. Denna renoveringsplan är orimlig i praktiken på grund av att ingen hänsyn tas till vilket fasadmaterial eller takfot byggnaden har. För många byggnader är det inte möjligt att utföra exempelvis tilläggsisolering på grund av bevarandevärden som presenterades i avsnitt 2.6.2. Detta innebär att detta förslag inte är möjligt att implementera i verkligheten och detta finns enbart med som ett extremfall att jämföra med.

**Renoveringsplan 3**, figur 5.3, delar in byggnader i olika kategorier baserat på energiklass, takform och fasadmaterial. Idén bakom denna renoveringsplan var att dela in byggnaderna i grupper som är lämpade för olika renoveringspaket mer specifikt genom att ta hänsyn till den aktuella byggnadens karakteristik. Detta gav upphov till en mer byggnadsspecifikt anpassad renoveringsplan.

**Renoveringsplan 4**, figur 5.4, är snarlik plan 3 från föregående stycke. Skillnaden blev att vara något mer frikostlig och även överväga paket 2 och 3 för byggnader från energiklass D, för att förhoppningsvis uppnå en högre energibesparing. Intressant är att jämföra resultaten mellan plan 3 och plan 4.

**Renoveringsplan 5**, figur 5.5, är även denna en utveckling av renoveringsplan 3. Tanken bakom denna plan var att för byggnader som redan har en låg energiprestanda, energiklass A-C, behöver förhoppningsvis ingen energibesparande renovering utföras överhuvudtaget. Genom att utesluta denna grupp av byggnader var förhoppningen att få ungefär samma energibesparing som för plan 3 fast till en lägre kostnad.

**Renoveringsplan 6**, figur 5.6, är också en utveckling av renoveringsplan 3. Tillägget från plan 3 är att de byggnader som kvalificerar sig för renoveringspaket 3 också granskas avseende byggår. Tanken med denna renoveringsplan var densamma som för plan 3, med förändringen att göra en prioritering av de byggnader som är äldre och på så sätt förväntas vara i mer akut behov av renovering.

**Renoveringsplan 7**, figur 5.7, är en kombination av renoveringsplan 5 och 6. Tanken här var att hitta en kostnadseffektiv plan som dessutom prioriterar att renovera äldre byggnader framför nyare.

## 6.3 Resultatdiskussion och analys

Denna studie har, efter noggrann databehandling och utvärdering av maskininlärningsmodeller, genererat ett resultat i form av information som kan användas vid uppdatering av den nationella renoveringsstrategin. Den byggnadsspecifika information som efterfrågats rörande det svenska flerbostadshusbeståndet har predikerats med tillräckligt god träffsäkerhet. Nedan diskuteras de ingående delar av resultatet, som bidragit till att besvara de frågeställningar som presenterades i början av rapporten.

### 6.3.1 Användandet av maskininläring och träffsäkerhet

*Hur och med vilken träffsäkerhet kan maskininläring användas för klassificering av olika byggnadsparametrar?*

Resultatet som presenterades i avsnitt 5.1.1 bevisar att det är möjligt att använda maskininläring i syfte att klassificera olika byggnadsparametrar. Både *logistisk regression* och *support vector machines* visade sig vara klassificeringsalgoritmer som genererade tillfredställande resultat. Högst träffsäkerhet, 93,4%, uppnåddes vid prediktion av takform. Att denna precision blev så hög i just detta fall, i förhållande till övriga byggnadsparametrar, beror förmodligen på förenklingen som gjordes av denna modell i avsnitt 3.5.3. När modellen endast behövde avgöra om takform var fläktrum eller inte blev den mindre komplex och predikerade således oftare rätt utfall.

Maskininlärningsmodellen för prediktion av byggnadskategori uppnådde, enligt tabell 5.1, en träffsäkerhet på 88,9%. Att denna byggnadsparameter erhöll en hög träffsäkerhet var önskvärt då detta var prioriterat i projektet. Byggnadens kategori var det som avgjorde vilken procentuell energibesparing och kostnad som skulle hämtas från studien, *Saga eller verklighet* [2], och appliceras på den aktuella byggnaden. En hög träffsäkerhet för prediktion av byggnadskategori säkerställde alltså att rätt värden blev hämtade för respektive byggnad och därmed blev energibesparing och kostnad korrekt beräknat för hela det svenska flerbostadshusbeståndet.

Att maskininlärningsmodellen för byggnadskategori erhöll en högre träffsäkerhet, jämfört med de oförenklade modellerna för byggnadskaraktistikerna, var väntat. De features som fanns tillgängliga i projektet kunde lättare skilja byggnadskategorier åt än byggnadskaraktistikerna. Byggår och antal våningar är exempel på features som tydligt kunde särskilja byggnadskategorierna. Detta beror på att, enligt tabell 2.1, de olika byggnadskategorierna kännetecknas av att de byggdes under varierande årtal. Dessutom är det känt att det normala antalet våningar för varje byggnadskategori skiljer sig åt. Lika självklara features, som de för byggnadskategori, fanns inte tillgängliga för prediktion av byggnadskaraktistikerna vilket är en anledning till den sämre träffsäkerheten vid dessa prediktioner.

I detta projekt ägnade författarna mycket tid åt att undersöka och "lära känna" data. Att författarna fokuserade på detta ledde till att en god förståelse förvärvades om de features och karaktistikerna som fanns tillgängliga i projektet. Denna kunskap visade sig vara nödvändig vid urvalet av maskininlärningsmodellerna. De features som ansågs vara relevanta och användes var avgörande för hur bra

maskininlärningsmodellerna blev. Om de features som används i en modell är opassande, är det inte möjligt att träna en maskininlärningsmodell till ett bra resultat. Lära känna datan bör alltså vara högt prioriterat vid maskininlärningsarbete.

Efter att observation av byggnaderna var utförda upptäcktes att datasetet, som skulle användas till maskininlärning, var obalanserat. Det vill säga andelen lamellhus utgjorde en stor del av totalt antal byggnader. Med ett obalanserat dataset kan resultatet bli missvisande på så sätt att en hög träffsäkerhet kan erhållas även om modellen endast lär sig att prediktera den kategori som är överrepresenterad i datan, i detta fall lamellhus. För att säkerställa att resultatet i projektet inte påverkades av detta fenomen undersöktes träffsäkerheten enskilt för varje utfall av byggnadskategorierna, se tabell 3.11. Att denna kontroll utfördes, stärker tillförlitligheten av studiens resultat.

I tabell 3.11 går det att utläsa att maskininlärningsmodellen för byggnadskategori hade svårt att identifiera och prediktera utfallet *annan kategori*. I själva verket lyckades inte modellen förutsäga denna rätt någon gång, vilket ledde till en träffsäkerhet på 0% när modellen testades på testsetet. *Annan kategori* användes för att klassificera byggnader som inte gick att tilldela till någon av de övriga tillgängliga kategorierna under observationerna. Det är därför inte så konstigt att modellen hade svårt att urskilja en byggnad som *annan kategori*, eftersom det inte finns något som kännetecknar dessa byggnader, utöver att de inte kan klassificeras som någon av de andra byggnadskategorierna. När prediktion skedde på flerbostadshusbeståndet förutsågs endast en liten del vara *annan kategori*. Eftersom modellen inte lyckades träffa någon av dessa byggnader på testsetet kan man inte heller med någon säkerhet säga att prediktionen av *annan kategori* är korrekt vid prediktionen på det svenska flerbostadshusbeståndet. Detta utgör istället en felkälla i prediktionen på grund av modellens problem med att identifiera och därmed också prediktera *annan kategori*. Denna felkälla är troligtvis en avgörande faktor till varför modellen inte uppnår en högre träffsäkerhet.

### 6.3.2 Procentuell fördelning av byggnadsparametrar

*Hur fördelar sig byggnadsparametrar procentuellt för det svenska flerbostadshusbeståndet från 1945-1975?*

Efter att det konstaterats att maskininlärning är användbart på denna typ av frågeställningar kunde byggnadsparametrarna predikteras för det svenska flerbostadshusbeståndet. Resultatet från detta gav en tydlig bild över vilka byggnadskategorier samt vilka karakteristiska drag som är mest återkommande för beståndet.

I resultatdelen, se avsnitt 5.1.2, presenterades den procentuella fördelningen av byggnadsparametrarna både baserat på: *antal EPC:er* samt total uppvärmd area, *Atemp*. Att fördelningen presenterades på två sätt berodde på att dataseten som användes vid prediktion utgick ifrån unika antal EPC:er och det föll sig därför naturligt att prediktera, och därmed generera, resultat baserat på detta. Vid senare eftertanke förstod författarna att denna fördelning enbart visar hur många EPC:er som är kopplade till de olika byggnadsparametrarna. Detta ger inte en rättvisande bild om hur beståndet ser ut i sin helhet. Ett mer korrekt sätt att presentera resultatet är att basera fördelning på *Atemp* istället. Detta ger en

bättre förståelse för hur omfattande en renovering per byggnadskategori skulle bli. Utöver detta baseras de energibesparande beräkningarna i *Saga eller verklighet* [2] på Atemp. Då detta projekt utgår från beräkningar i *Saga eller verklighet* [2] var det därför praktiskt att basera den procentuella fördelningen på Atemp. Detta resultat gav en förståelse för hur en energibesparande renoveringsplan påverkar beståndet i sin helhet och författarnas slutsats är att en procentuell fördelning baserat på Atemp ger ett användbart resultat.

Vidare går det att från tabell 5.2 utläsa att lamellhusen absolut är den dominerande byggnadskategorin i beståndet från aktuell tidsperiod. Detta resultat var väntat, då lamellhusen är den byggnadskategori som kontinuerligt byggs under 1945-1975. Detta är ett intressant resultat då Miljonprogrammet, vilket dominerade under denna tid, för många är mer känt som höga betonghus. Resultatet från denna studie kan komma att ändra denna uppfattning.

Med vetskapen om att lamellhusen var såpass dominerande i hela beståndet funderade författarna ut en förbättringsmöjlighet kring detta. Redan under observationerna hade en snävare indelning av denna byggnadskategori kunnat utföras. Detta hade troligtvis genererat ännu mer byggnadsspecifika renoveringsplaner, vilket hade gett ytterligare mervärde i form av bättre förståelse för hur energibesparingar hade kunnat åstadkommas. Att detta inte gjordes i projektet berodde på att författarna kom till denna insikt efter att en stor andel av observationerna redan utförts. Dessutom konstaterades, att en snävare indelning, hade varit mer komplex och svårlost med de maskinlärningsmodeller som tagits fram i detta arbete. Nya modeller hade behövt genereras och utvärderas. Denna insikt skulle dock kunna bidra till en utveckling av detta arbete i framtiden.

I tabell 3.2 presenterades karakteristiker som lades till under arbetets gång. Nedan förklaras tanken bakom dessa:

- **Gavelmaterial** antogs vara avgörande inför en tilläggsisolering i paket 3, se avsnitt 2.6.1. För de byggnader där gavelmaterialet är tegel till skillnad från fasadmaterialet på övriga ytterväggar tilläggsisoleras inte hela byggnaden. Detta blir missvisande i de energibesparingar som beräknats i detta projekt eftersom beräkningar gjorts för tilläggsisolering av byggnadens samtliga ytterfasader.
- **Inglasad balkong** förväntades antyda att energibesparande renovering redan utförts på byggnaden. Som beskrevs i avsnitt 2.3 medför en inglasad balkong en energibesparing.
- **Fönsterband på lamellhus** förväntades tillföra information som skulle kunna skilja lamellhusen åt för att möjliggöra ännu mer byggnadspecifika indelning som beskrevs högre upp i detta avsnitt.
- **Observerat antal våningar** lades till för att kunna kontrollera att informationen i energideklarationerna stämde överens med den byggnad som observerades för att säkerställa kvalitén på datan.

Dessa karakteristiska drag förväntades i början av projektet, baserat på ovan nämnda argument, spela en avgörande roll vid generering av renoveringsplaner. Författarna insåg senare, att inkludering av dessa hade bidragit till ett för omfattande arbete vid generering av renoveringsplaner då beräkningsunderlag för detta saknades. Att byggnadsparametrarna togs upp i rapporten men aldrig presenterades som resultat, i form av procentuell fördelning för flerbostadshusbeståndet, berodde alltså på att de aldrig predikterades men att författarna gärna hade inkluderat dessa för att kunna beräkna ännu mer specifika energibesparingar. Detta var inte möjligt i projektet men parametrarna finns kvar som idé för att gynna vidare arbete, inom detta område, i framtiden.

### 6.3.3 Lämpliga renoveringsplaner

*Hur kan lämpliga renoveringsplaner för det svenska flerbostadshusbeståndet från 1945-1975 se ut?*

De renoveringsplaner som tagits fram och förväntas ligga till grund för uppdateringen av den nationella renoveringsstrategin presenterades i figur 5.1-5.7. Som går att avläsa i figurerna går renoveringsplanerna att variera utifrån önskemål. Variationerna beror främst på vilket syfte en renoveringsplan ska uppfylla. Exempelvis går det att uppnå en lägre energibesparing med *plan 1*, då till en lägre kostnad. Behöver en större energibesparing uppnås, borde fokus ligga på att utgå från *plan 3* till *plan 7*. Här behöver en avvägning göras om kostnad eller energibesparing ska prioriteras. Ytterligare en aspekt som kan vara avgörande vid val av renoveringsplan är om antal tilläggsisoleringar för beståndet ska beaktas med hänsyn tagen till bevarandevärde, se avsnitt 2.6.2. En del områden kan vara av ett högre kulturhistoriskt värde och en renoveringsplan med färre planerade tilläggsisoleringar skulle därför kunna anses vara mer lämplig.

Ett sätt att jämföra renoveringsplanerna med varandra är att utgå från den högra kolumnen i tabell 5.8 som presenterar *energibesparing per investerad krona*. Denna parameter gör att energibesparing sätts i relation till hur mycket en investering kostar. Även här går det att se hur nämnda renoveringsplaner förhåller sig liknande till varandra och det kan vara svårt att avgöra vilken av planerna som skulle vara mest optimal. Författarna har beslutat att enbart presentera förslagen och därför förs inget resonemang kring vilken plan som skulle vara mest lämplig att tillämpa på det svenska flerbostadshusbeståndet.

För den intresserade går det att föra resonemang om vilken renoveringsplan som är lämplig för aktuellt ändamål. Figur 5.8 visualiserar hur de olika byggnadskategorierna är fördelade på renoveringspaket och renoveringsplan. Figuren visar att byggnadskategorierna *punkthus* och *skivhus* inte är optimerade för varken paket 2 eller paket 3. Detta beror främst på att dessa byggnader ofta har fläktrum på taket och saknar takutsprång. Med denna vetskap, skulle en slutsats kring projektets presenterade renoveringsplaner vara, att fokus bör ligga på den dominerande byggnadskategorin *lamellhus*. Dessa utgör en såpass stor del av beståndet och åtgärder lämpar sig framförallt med paket 2 men också paket 3. Vid planerade renoveringar kan lamellhusen bidra till betydande energibesparing i det svenska flerbostadshusbeståndet.

Författarna har också, med denna studie, kommit fram till att faktorn *energiklass* i energideklarationerna, se avsnitt 2.4.1, är en mycket användbar parameter för att bedöma renoveringsbehovet av en byggnad. En energieffektiviserande åtgärd kan medföra att en byggnad, som tidigare klassats med exempelvis ener-

giklass E, kan bli omskalad till exempelvis A-C. Är målet att samtliga byggnader i beståndet ska tillhöra energiklass A-C så gäller det att utföra åtgärder på de byggnader som är i behov av energibesparande ingrepp, tillhörande energiklass D-G, först. Energitklass gör det möjligt att jämföra byggnader och på detta sätt få en balans mellan äldre och nyare byggnader i beståndet. Kanske går det med denna vetenskap att besluta om en renoveringsåtgärd är lönsam eller om det är mer värdefullt att riva och bygga helt nya byggnader som är mer energieffektiva.

De renoveringsplaner som presenterats i denna studie utgår från ett scenario där aspekter som försvårar renoveringsarbetet inte tagits i beaktning. Ett exempel som författarna antar kan försvåra, framförallt vid tilläggsisolering, är balkongernas existens. En byggnad som helt saknar balkonger, förväntas vara lättare att tilläggsisolera än en byggnad som är försedd med balkonger. Utöver detta har författarna antagit att en högre byggnad, med fler antal våningar, skulle kunna vara svårare att åtgärda med hänsyn tagen till byggkranarnas kapacitet. Ytterligare en aspekt som diskuterats är att en tätortsparameter skulle kunna spela en avgörande roll. Det är förväntat att det är mer lättillgängligt att renovera en byggnad i glesbygden i jämförelse med en byggnad i en tät bebyggd miljö. Faktorer som dessa anses kunna försvåra renoveringsarbetet och därmed förhindra att framtagna renoveringsplaner är applicerbara på beståndet.

Beräkningarna för energibesparing och kostnad för renoveringsplanerna baserades på siffror hämtade ur studien *Saga eller verklighet* [2]. Likheterna som går att identifiera mellan studien och detta projekt är att byggnadsbeståndet delats in i separata byggnadskategorier. Byggnadskategorierna har därefter studerats och beräkningar har gjorts för varje enskild *typbyggnad*. Skillnaderna som finns i beräkningarna är att det i detta projekt skalats upp på storskalig nationell nivå, vilket innebär att hela det svenska flerbostadshusbeståndet har tagits i beaktning och inte enbart *typbyggnader* från *Saga eller verklighet* separat. I *Saga eller verklighet* presenteras inga övergripande renoveringsplaner, vilket det gör i detta projekt, detta är en stor skillnad dessa studier emellan. I detta projekt beskrivs renoveringsplanerna för att få en förståelse för de energibesparingar som kan uppnås i det stora hela.

#### 6.3.4 Energibesparing och kostnad

*Vad resulterar renoveringsplanerna i för energibesparing och kostnad?*

Renoveringsplanerna från figur 5.1-5.7 resulterade som bekant i energibesparing och kostnad enligt tabell 5.8. Resultatet visar att en större energibesparing implicerar en större investering. Parametern *energi-besparing per krona* kan vara värdefull att ta hänsyn till för att ta både energibesparing och kostnad i beaktning. *Renoveringsplan 3* till *plan 7* ger liknande resultat avseende energibesparing och kostnad.

Vid beräkning av resultatet, som presenteras i tabell 5.8, har det antagits att samtliga byggnader renoveras direkt enligt respektive renoveringsplan. Detta är ett antagande som inte är möjligt att utföra praktiskt i verkligheten. Ett mer realistiskt scenario hade varit att med hjälp av en tidsplan dela upp renoveringsåtgärderna under en längre period på flera år. Detta hade dock försvårat beräkningarna och komplicerat känslighetsanalysen som presenterades i avsnitt 5.2.2. I denna känslighetsanalys hade återbetlaningstiden samt det årliga kassaflödet förändrats med tanke på att det under flera år skulle

ha investerats i renovering av byggnader istället för en enda stor investering första året.

Som presenterades i avsnitt 2.6.3.1, utgår renoveringskostnaderna i studien *Saga eller verklighet* [2], från marginalkostnader. Detta innebär att kostnaden för de olika energieffektiviserande renoveringsplaner som presenteras i detta arbete är betydligt lägre än om hela kostnadsbilden för de totala renoveringarna av byggnaden skulle ha tagits med i beräkningarna. Detta gör att den ekonomiska kalkylen är något bristfällig och inkluderar inte kostnaderna för den redan planerade renoveringen.

I projektet utfördes en känslighetsanalys, som presenterades i avsnitt 5.2.2, för att beräkna återbetalningstiden för respektive renoveringsplan. Renoveringsplan 1 har kortast återbetalningstid och plan 3-7 uppnår snarlika återbetalningstider sinsemellan. Samtliga renoveringsplaner skär x-axeln när kalkylräntan är 0 respektive 5% se figur 5.10 och 5.11 vilket indikerar att investeringarna är hållbara i den mån att de återbalar sig inom tidsperioden 40 år. Om däremot kalkylräntan höjs till 10%, figur 5.12, är det endast för extremfallet renoveringsplan 1 som investeringen återbetalas inom 40 år tack vare den årliga kostnadsreducering som den uppnådda energibesparingen medför. Detta innebär att renoveringsplan 1 kan anses som den säkraste investeringen om hänsyn tas till enbart kostnaden och inte energibesparingen som för denna plan enbart är 11,8%. Som nämnt i föregående stycke bygger kostnaderna i denna studie på marginalkostnader och visar alltså inte hela kostnadsbilden för renoveringsplanerna. Detta gör att denna känslighetsanalys inte kan anses helt trovärdig och slutsatser ska tas med försiktighet. Denna osäkerhet i känslighetsanalysen är anledningen till att författarna inte ger denna analys mer fokus i rapporten.

De framtagna renoveringsplanerna *plan 3* till *7* uppnår en energibesparing på ungefär 35% vardera. Någoting som är värt att notera är att en energibesparing på 35% inte uppfyller det krav som Sverige har satt upp, se avsnitt 2.5, som innebär att Sverige ska ha 50% mer effektiv energianvändning 2030 jämfört med 2005. De energieffektiviserande åtgärder, som inkluderas i renoveringsplanerna, förhindrar inte att andra energibesparande åtgärder kan tillämpas på byggnaden. En åtgärd som kan utföras är bland annat att placera solceller på byggnadens tak, vilket är energibesparande på lång sikt. I denna studie har detta inte varit med i beräkningarna men hypotesen är att energibesparingen skulle kunna bli högre än 35% om noggrann utvärdering av byggnaden görs och ytterligare lämpliga åtgärder vidtas.

### 6.3.5 Brister och förbättringsmöjligheter

Någoting som upptäcktes då observationerna gjordes var att datan, det vill säga informationen från energideklarationerna och Lantmäteriet, i några fall var okonsekvent. Framförallt var det i en del fall noterat fler trappor än bostäder i en byggnad. Detta innebär alltså att det finns fler trappuppgångar än det finns lägenheter i byggnaden, vilket är ett orealistiskt scenario för ett flerbostadshus. Detta ansåg författarna vara orimligt och därav plockades dessa, 22 datapunkter, bort från datasetet. Utöver denna felnotering i data visade det sig att *antal våningar* i några fall inte stämde överens med det våningsantal som observerades med Google maps. Författarna antog att detta berodde på att när energideklarationen skapats har antal våningar blivit felnoterad på grund av den mänskliga faktorn eller att byggnaden inte har besökts fysiskt innan notering. I något fall var våningsantalet registrerat som 50, vilket inte är möjligt



för de flerbostadshus som representerar den aktuella tidsperioden. Denna siffra antogs vara felnoterad i form av att en nolla för mycket tillkommit. När författarna gjorde en observation på denna byggnad, för att undersöka våningsantalet, var det fem våningar och hypotesen verkade stämma.

Vid observation av byggnaderna noterades vid flera tillfällen att olika fasadmateriell fanns representerade på en och samma byggnad. Detta medförde att personen som observerade byggnaden var tvungen att själv ta beslut om vilket fasadmateriell som var dominerande för byggnaden och notera detta för observationen. Detta innebär således en osäkerhet i observationerna eftersom detta tillvägagångssätt inte gick att standardisera. Vid observationerna upptäcktes också att en del byggnader endast hade balkonger åt ett väderstreck, vilket bidrar med en osäkerhet eftersom många byggnader endast kunnat undersökas från en sida med verktyget Google street view. Detta medför att det finns risk för att vissa byggnader klassificerats som byggnader utan balkong när de i själva verket har balkonger. Det upptäcktes dessutom att vid observation av takform, framförallt takformen sadeltak, var taknocksvinkeln kraftigt varierande. Detta medförde att sadeltaken har stor variation i utseende och det hade varit önskvärt att dela in dessa tak mer specifikt för mer optimerade renoveringsplaner.

I paket 3 i studien *Saga eller verklighet* [2], finns det beräkningsunderlag för byte av fönster till lågenergifönster. Denna kostnadspost är stor och bidrar till att paket 3 innebär en dyr investering. För att beräkna priset för detta i projektet har kostnaden tagits för en genomsnittligt stor byggnad och applicerats på antalet byggnader som genomförde paket 3. För att få denna kostnadspost mer korrekt i denna studie hade det varit intressant att ha data på hur många, och hur stora, fönster byggnaden har. Denna data är svår att observera på en byggnad, men att lägga till det som en punkt vid genomförandet av energideklarationer skulle vara en god idé.

Under observationerna användes funktionen *flygplansvy*, för att observera byggnaden ovanifrån, i Google street view flitigt. Denna funktion möjliggjorde observation av byggnadens tak och hjälpte på så sätt till att bedöma byggnadens takform. Värt att notera är att denna funktion nu är borttagen och observationer går inte att utföra på detta sätt längre.

# Kapitel 7

## Slutsats

Detta examensarbete bidrar med ny användbar information gällande byggnadsparametrar för det svenska flerbostadshusbeståndet, från åren 1945-1975, som kan användas vid utformningen av den uppdaterade nationella renoveringsstrategin. Resultatet presenterar procentuell fördelning av byggnadsparametrar för beståndet uppskalad på nationell nivå. Utöver detta har renoveringsplaner presenterats där energibesparing per investerad krona har beräknats. Syftet och målen med studien har uppnåtts genom att ett utökat dataunderlag genererats och datan noggrant bearbetats. Därefter har olika maskininlärningsmodeller tränats, utvärderats samt jämförts för att slutligen väljas för respektive byggnadsparameter. När modellerna var valda predikterades den procentuella fördelningen av byggnadsparametrarna på det svenska flerbostadshusbeståndet. Slutligen presenterades förslag på lämpliga energibesparande renoveringsplaner. Utifrån de genererade resultaten presenteras studiens slutsatser nedan:

- Maskininläring är ett användbart verktyg att tillämpa för denna typ av klassificeringsproblem. Med denna metodik har byggnadskategorier och byggnadskarakteristiker predikterats för det svenska flerbostadshusbeståndet från åren 1945-1975. *Logistisk regression* och *support vector machines* är de metoder som använts med slutliga träffsäkerheter på mellan 67-93%. I detta projekt fanns det många välfungerande features för prediktion av byggnadskategori, då denna byggnadsparameter har tydlig koppling till bland annat *byggår* och *våningsantal*. För övriga byggnadsparametrar var tillgängliga features inte lika anpassade och modellerna genererade mindre precisa träffsäkerheter.
- Det svenska flerbostadshusbeståndet domineras av byggnadskategorin lamellhus med hela 69% följt av skivhus på 18,5%. Om en byggnad har takutsprång eller inte är relativt jämt fördelat för hela beståndet. Denna jämna fördelning återfinns inte för byggnadsparametrarna *takform* och *fasadmaterial*. Tak försedda med fläktrum utgör 21,3% och tegelfasader kan noteras på 36,3% av flerbostadshusen från aktuell tidsperiod.

- Kombinationer av byggnadsspecifika särdrag kan ligga till grund för vilka energibesparande åtgärder som bör tillämpas på respektive byggnad i beståndet. Lämpliga energieffektiviserande renoveringsplaner för det svenska flerbostadshusbeståndet utgår med fördel från *byggnadskategori* samt karakteristiker som bland annat beskriver byggnadens *takform* och *fasadmaterial*. När planerna genereras är energiklass också avgörande tack vare dess mått på en byggnads energiprestanda.
- Studien förutsäger ett mer realistiskt scenario av hur energieffektivisering kan ske och ligga till grund för den nationella renoveringsstrategin. Rimliga renoveringsplaner förväntas bidra med cirka 35% energibesparing, motsvarande 3,2 kWh per investerad krona, baserat på ny byggnadsspecifik information om det svenska flerbostadshusbeståndet som genererats i denna studie.

Resultatet från denna studie kan användas med syfte att förstå den upprustning som behöver göras rörande Folkhemmet och Rekordåren för att uppnå betydande energibesparingar inom sektorn *bostäder och service*. Projektets idé och tillvägagångssätt kan tänkas ligga till grund för andra sammanhang, där ytterligare byggnadsspecifika karakteristiker behöver tas fram, utöver de som presenterats här. Om så är fallet uppmanar författarna till att utöka dataunderlaget. Resonemang bör föras kring om det finns ytterligare databaser, med värdefull information om beståndet, möjliga att använda som kompletterande dataunderlag vid maskininlärningsarbetet.

# Litteraturförteckning

- [1] Mikael Mangold. Artificiell intelligens för tolkning av renoveringsbehov.  
<https://www.e2b2.se/aktuellt/genomfoerda-moeten/190208-%C3%A5rskonferens-2019/190208-kortintervju-mikael-mangold/>, 2019.  
Online, hämtad 2020-01-04.
- [2] VVS Företagen i samarbete med institutionen för energiteknik vid Kungliga Tekniska Högskolan & White arkitekter AB. *Lönsam energieffektivisering - Saga eller verklighet?* VVS Företagen, 2012.
- [3] Sveriges Riksdag. Energieffektiviseringsdirektivet och direktivet om byggnaders energiprestanda.  
[https://www.riksdagen.se/sv/dokument-lagar/dokument/fakta-pm-om-eu-forslag/energieffektiviseringsdirektivet-och-direktivet\\_H406FPM43](https://www.riksdagen.se/sv/dokument-lagar/dokument/fakta-pm-om-eu-forslag/energieffektiviseringsdirektivet-och-direktivet_H406FPM43), 2016.  
Online, hämtad 2019-10-05.
- [4] Europeiska kommissionen. Energy performance of buildings directive.  
<https://ec.europa.eu/energy/en/topics/energy-efficiency/energy-performance/-of-buildings/energy-performance-buildings-directive>, 2019.  
Online, hämtad 2019-10-05.
- [5] Boverket. Vad innebär det omarbetade EU-direktivet EPBD?  
<https://www.boverket.se/sv/byggande/bygg-och-renovera-energieffektivt/nyheter-inom-energiomradet/vad-innebar-det-omarbetade-eu-direktivet-epbd/>, 2018.  
Online, hämtad 2019-10-05.
- [6] Boverket. Underlag till den andra nationella strategin för energieffektiviserande renovering.  
<https://www.boverket.se/sv/om-boverket/publicerat-av-boverket/publikationer/2016/underlag-till-den-andra-nationella-strategin-for-energieffektiviserande-renovering/>, 2016.  
Online, hämtad 2019-10-05.
- [7] Anna Pettersson. Långsiktig renoveringsstrategi.  
<https://www.energimyndigheten.se/energieffektivisering/program-och-uppdrag/langsiktig-renoveringsstrategi/>, 2019.  
Online, hämtad 2019-10-17.
- [8] Mikael Mangold. Nationell byggnadsspecifik information.  
<https://www.ri.se/sv/vad-vi-gor/projekt/nationell-byggnadsspecifik-information>, uå.  
Online, hämtad 2019-10-05.

- [9] Kristina Mjörnell & Eva-Lotta Kurkinen. Renovering av befintligt bostadsbestånd.  
[https://www.e2b2.se/library/4084/syntes\\_e2b2\\_renovering\\_av\\_befintligt\\_bostadsbestand.pdf?fbclid=IwAR0k4eiLvIv1bQINqAnk82vvQjbY\\_AmBWr5h6HzZPfiGhy6HYZIJ1Sj3BIg](https://www.e2b2.se/library/4084/syntes_e2b2_renovering_av_befintligt_bostadsbestand.pdf?fbclid=IwAR0k4eiLvIv1bQINqAnk82vvQjbY_AmBWr5h6HzZPfiGhy6HYZIJ1Sj3BIg), uå.  
Online, hämtad 2019-10-05.
- [10] Eva Rudberg. *Folkhemmets byggande*. AB Trycksaker, första utgåvan edition, 1992.
- [11] Boverket. Under miljonprogrammet byggdes en miljon bostäder.  
<https://www.boverket.se/sv/samhallsplanering/stadsutveckling/miljonprogrammet/>,  
2014.  
Online, hämtad 2019-10-23.
- [12] Allmännyttan. Kritiken mot miljonprogrammet.  
<https://www.allmannyttan.se/historia/tidslinje/kritiken-mot-miljonprogrammet/>, uå.  
Online, hämtad 2019-12-10.
- [13] Energimyndigheten Boverket and Naturvårdsverket. *Renovera miljonprogrammet energismart*. 2010.
- [14] Hans Lind. Leder hyreslagens regler till rätt renoveringar: analys och förslag.  
[http://www.renoveringscentrum.lth.se/fileadmin/renoveringscentrum/SIRen/Publikationer/Leder\\_hyreslagens\\_regler\\_till\\_ratt\\_renovering.pdf](http://www.renoveringscentrum.lth.se/fileadmin/renoveringscentrum/SIRen/Publikationer/Leder_hyreslagens_regler_till_ratt_renovering.pdf), 2015.  
Online, hämtad 2019-12-12.
- [15] Sonja Vidén. *Miljonprogrammet - utveckla eller avveckla?* Formas Fokuserar, 2012.
- [16] Frakka AB. Ordlista.  
<https://frakka.se/kunskapsbas/ordlista/#toggle-id-293>, uå.  
Online, hämtad 2019-10-23.
- [17] Boverket. En- och tvåbostadshus.  
[https://www.boverket.se/sv/PBL-kunskapsbanken/lov--byggande/anmalningsplikt/bygglovbefriade-atgarder/en--och-tvabostad\\_tomt/en\\_tvabostad/](https://www.boverket.se/sv/PBL-kunskapsbanken/lov--byggande/anmalningsplikt/bygglovbefriade-atgarder/en--och-tvabostad_tomt/en_tvabostad/), 2018.  
Online, hämtad 2019-10-17.
- [18] Byggipedia. Fasadutformning och -material.  
<https://byggipedia.se/byggteknik/fasader/fasadmaterial-och-utforande/>, uå.  
Online, hämtad 2019-10-17.
- [19] Vårgårdahus. Sadeltak eller pulpettak?  
<https://www.vargardahus.se/tips/2019/5/16/sadeltak-eller-pulpetttak>, 2019.  
Online, hämtad 2019-09-28.

- [20] Elina Blom Westergren. Bygga platt tak med säker konstruktion.  
<https://www.byggahus.se/bygga/bygga-platt-tak-saker-konstruktion>, 2018.  
Online, hämtad 2019-09-28.
- [21] Bror Gustafsson. Genomförandebeslut om renovering av tak samt byggande av nya fläktrum på första sim- & idrottshall.  
<https://insynsverige.se/documentHandler.ashx?did=91841>, 2008.  
Online, hämtad 2019-09-28.
- [22] Google. Google street view.  
<https://www.google.com/maps/@60.6769284,17.135918,3a,16.9y,338.11h,118.24t/data=!3m6!1e1!3m4!1sTtNr0FKoAPRs0LvDn0vBjg!2e0!7i13312!8i6656>, 2010.  
Online, hämtad 2019-12-12.
- [23] Google. Google street view.  
<https://bit.ly/2T4jqX0>, 2017.  
Online, hämtad 2019-12-12.
- [24] Google. Google street view.  
<https://www.google.se/maps/@55.6976703,13.2006902,3a,75y,3.4h,92.01t/data=!3m6!1e1!3m4!1s04YeLMi6XaSMWLL0Ve64pg!2e0!7i13312!8i6656>, 2014.  
Online, hämtad 2019-12-12.
- [25] Google. Google street view.  
<https://bit.ly/2R0n3Ls>, 2019.  
Online, hämtad 2019-10-05.
- [26] Polarpumpen.se. Vad är takfot?  
<https://www.polarpumpen.se/avfuktare/fuktlexikon/takfot>, uå.  
Online, hämtad 2019-09-28.
- [27] Arkitektur Stockholm. Vägledning balkonger. *Stockholm stad*, 38(1):13–15, 2011.
- [28] Hans Dahlquist. Kapa kostnader med inglasad balkong.  
<https://www.nyteknik.se/energi/kapa-kostnader-med-inglasad-balkong-6424287>, 2010.  
Online, hämtad 2019-12-12.
- [29] Google. Google street view.  
[https://www.google.se/maps/@59.309846,18.1141044,3a,33.5y,291.12h,106.5t/data=!3m6!1e1!3m4!1sL1o7zvRNmFuNnQiB43\\_yHg!2e0!7i13312!8i6656](https://www.google.se/maps/@59.309846,18.1141044,3a,33.5y,291.12h,106.5t/data=!3m6!1e1!3m4!1sL1o7zvRNmFuNnQiB43_yHg!2e0!7i13312!8i6656), 2017.  
Online, hämtad 2020-01-09.

- [30] Google. Google street view.  
<https://www.google.se/maps/@55.5973685,12.9906818,3a,75y,142.45h,99.18t/data=!3m6!1e1!3m4!1sp5ASa08DNvjN4-dJLzJmuw!2e0!7i13312!8i6656>, 2017.  
Online, hämtad 2020-01-09.
- [31] Boverket. Dessa byggnader ska energideklarerars.  
<https://www.boverket.se/sv/energideklaration/energideklaration/dessa-byggnader-ska-energideklarerars/>, 2019.  
Online, hämtad 2019-10-05.
- [32] Dag Henning. Energieffektivisering.  
<https://www.naturvardsverket.se/Miljoarbete-i-samhallet/Miljoarbete-i-Sverige/Uppdelat-efter-omrade/Energi/Energieffektivisering/>, 2019.  
Online, hämtad 2019-10-05.
- [33] HSB. Bättre koll på energiförbrukningen med energideklaration.  
<https://www.hsb.se/stockholm/forvaltningstjanster/energioptimering-och-drift/energideklaration/>, uå.  
Online, hämtad 2019-10-17.
- [34] Boverket. Energieklarationens innehåll.  
<https://www.boverket.se/sv/energideklaration/energideklaration/energideklarationens-innehall>, 2019.  
Online, hämtad 2019-10-18.
- [35] Boverket. Atemp.  
<https://www.boverket.se/sv/byggande/bygg-och-renovera-energieffektivt/Atemp/>, 2014.  
Online, hämtad 2019-10-18.
- [36] Boverket. Beräkning av byggnadens energiprestanda.  
<https://www.boverket.se/sv/energideklaration/for-energiexperter/berakning-av-byggnadens-energianvandning/>, uå.  
Online, hämtad 2019-12-12.
- [37] Låganbygg. *Omybyggnation med sänkt energibehov*. Lågan - för energieffektiva byggnader, uå.
- [38] Energimyndigheten. Energiläget.  
<https://www.energimyndigheten.se/statistik/energilaget/>, 2019.  
Online, hämtad 2020-01-04.
- [39] Regeringskansliet. Överenskommelse om sveriges mål för energieffektivisering.  
<https://www.regeringen.se/pressmeddelanden/2016/11/overenskommelse-om-sveriges-/>

- mal-for-energieffektivisering/, 2016.  
Online, hämtad 2019-11-07.
- [40] Energimyndigheten. Sveriges energi- och klimatmål.  
<https://www.energimyndigheten.se/klimat--miljo/sveriges-energi--och-klimatmal/>,  
2019.  
Online, hämtad 2019-11-07.
- [41] Regeringskansliet. Sverige ska nå 50 % energieffektivisering – arbetet har inletts.  
<https://www.regeringen.se/artiklar/2017/08/sverige-ska-na-50-energieffektivisering/--arbetet-har-inletts/>, 2017.  
Online, hämtad 2019-11-07.
- [42] Carl-Johan Johansson. Morgondagens energimål säkras genom energieffektivisering idag.  
<https://www.energivarlden.se/artikel/morgondagens-energimal-sakras-genom/-energieffektivisering-idag/>, 2019.  
Online, hämtad 2019-11-07.
- [43] Solar region Skåne. Är det lönsamt med solceller?  
<https://solarregion.se/om-solenergi/solceller/ar-det-lonsamt-att-installera-solel/>,  
2019.  
Online, hämtad 2019-11-25.
- [44] Kristina Mjörnell, Thorbjörn Gustavsson, Kristina Fyhr, Pernilla Gervind, and Angela Sasic. *Miljoparena - Miljonsprogrammarena, Innovationva åtgärdsförslag för renovering av byggnadsskal och installationer*. 2011.
- [45] Christoffer Eskilsson Said Elmi. Jämförelsestudie av tilläggsisolering.  
<http://www.diva-portal.se/smash/get/diva2:643201/FULLTEXT01.pdf>, 2013.  
Online, hämtad 2019-11-25.
- [46] Sveriges Riksdag. Plan- och bygglag.  
[https://www.riksdagen.se/sv/dokument-lagar/dokument/svensk-forfattningssamling/plan--och-bygglag-2010900\\_sfs-2010-900](https://www.riksdagen.se/sv/dokument-lagar/dokument/svensk-forfattningssamling/plan--och-bygglag-2010900_sfs-2010-900), 2010.  
Online, hämtad 2019-11-07.
- [47] Lunds kommun. Kulturhistoriska byggnader, kulturmiljöer.  
<https://www.lund.se/bygga-bo--miljo/bygga-nytt-andra-eller-riva/kulturhistoriska-byggnader-kulturmiljoer/>, 2019.  
Online, hämtad 2019-11-16.
- [48] Dag Henning. Energieffektivisering i bostäder och lokaler.



- <https://www.naturvardsverket.se/Miljoarbete-i-samhallet/Miljoarbete-i-Sverige/Uppdelat-efter-omrade/Energi/Energieffektivisering/Bostader-och-lokaler/>, 2019.  
Online, hämtad 2019-11-16.
- [49] Lexico. Definition of artificial intelligence in english.  
[https://www.lexico.com/en/definition/artificial\\_intelligence](https://www.lexico.com/en/definition/artificial_intelligence), uå.  
Online, hämtad 2019-09-23.
- [50] Andrew Ng. Stanford University. lecture notes - machine learning.  
<https://www.coursera.org/learn/machine-learning/home/welcome>.  
Online, hämtad 2019-09-17.
- [51] Trevor Hastie Robert Tibshirani Gareth James, Daniela Witten. *An Introduction to Statistical Learning*. Springer, 2013.
- [52] Marti A. Hearst. Support vector machines.  
<http://web.cs.iastate.edu/~honaavar/heardst-svm.pdf>, uå.  
Online, hämtad 2019-10-05.
- [53] Scikit learn. Rbf svm parameters.  
[https://scikit-learn.org/stable/auto\\_examples/svm/plot\\_rbf\\_parameters.html](https://scikit-learn.org/stable/auto_examples/svm/plot_rbf_parameters.html), uå.  
Online, hämtad 2019-10-05.
- [54] K.K Patro, S.G.K Sahu. Normalization: A preprocessing stage. 2015.
- [55] Andries P. Engelbrecht. *Computational Intelligence An Introduction*. WILEY, second edition edition, 2007.