

# ELEKTRISK LASTPROGNOSTISERING FÖR BYGGNADER

Energiingenjör  
- Elkraft

John Bojestig



HÖGSKOLAN I BORÅS

## Förord

Detta examensarbete har utförts inom gruppen för Elsystem på Research Institute of Sweden (RISE) i Göteborg. Examensarbetet är ett obligatoriskt moment inom Energiingenjörsprogrammet på Högskolan i Borås.

Arbetet med detta projekt och utvecklandet av modellen har ställt stora krav på problemlösning och hitta egna vägar för att öka sin förståelse. Otaliga obegripliga felmeddelanden har även ställt tålamod och humör på prov. Dessa stundtals jobbiga motgångar man tagit sig ur är dock det man bär med sig. En lärdom från detta projektet är att saker som verkar obegripliga bara tar längre tid att förstå.

Jag vill passa på att tacka Elsystemsgruppen på RISE och min handledare Mattias Persson specifikt för all hjälp och stöd längs vägen men framför allt för att ni trodde på mig och gav mig chansen. Jag vill även tacka min examinator Peter Axelberg som med stor entusiasm och kunskap väglett detta arbete.

Göteborg, maj 2019  
John Bojestig

**Program:** Energiingenjör inriktning elkraft

**Svensk titel:** Elektrisk lastprognostisering för byggnader

**Engelsk titel:** Electrical load prediction for buildings

**Utgivningsår:** 2019

**Författare:** John Bojestig

**Handledare:** Mattias Persson

**Examinator:** Peter Axelberg

**Nyckelord:** Lastprognostisering, byggnad, neurala nätverk, k-mean clustering

---

### **Sammanfattning**

Om världen ska kunna ställa om till förnyelsebara energikällor krävs det nya och bättre tekniklösningar. En liten del av lösningen på balanseringsproblematiken på elnätet som icke-reglerbara energikällor som sol- och vindkraft står för kan vara att sköta en del av balanseringen lokalt i byggnader med hjälp av batterilager. För att kunna styra den balanseringen på ett optimalt sätt behöver styrningen ha prognoser för hur stor den elektriska lasten i byggnaden kommer vara framöver. Syftet med denna studie har varit att utföra en elektrisk lastprognostisering för en byggnad över ett dygn.

Modellen som utförde elektrisk lastprognostisering för en byggnad har baserats på neurala nätverk. Istället för att ha ett neuralt nätverk som prognostiserar över hela dygnet har 24 olika neurala nätverk prognostiserat varsin timma. Varje neuralt nätverk har valts efter tester mellan ett flertal neurala nätverk med variationer i parametrar som har tagits fram med hjälp av en klusteralgorithm.

Resultatet visade att modellen som tagits fram i studien prognostiserade den elektriska lasten i en byggnad över ett dygn med en felmarginal enligt mean average percentage error på 5.67%. Det gick även att se fördelar med att dela upp prognostiseringen i mindre delar och testa olika parametrar för varje timma som skulle prognostiseras.

Med avseende på jämförelser med andra studier och att bostadshus är ett välkänt svårt prognostiseringsproblem bör resultatet anses som godkänt. Det mesta tyder på att prognostiseringsmodellen är tillräckligt bra för att kunna assistera en smart styrning av ett batteri i en byggnad med användbar information.

## **Abstract**

If the world should be able to convert to renewable energy sources, new and better technical solutions is required. A small part of the solution to the balancing problem on the electricity grid, as non-controllable energy sources such as solar and wind power is highly responsible for, can be to handle part of the balancing locally in buildings using battery storage. In order to be able to control this balancing in the optimal way, the control system needs to have forecasts of how large the electric load in the building will be in the future. The aim of this study has been to carry out electrical load prediction for a building over one day.

The model that carried out electrical load forecasting for a building has been based on neural networks. Instead of having one neural network that predicts the whole day, 24 different neural networks have been forecasting each hour. Each neural network has been selected after testing between several neural networks with variations in parameters that have been selected using a cluster algorithm.

The result showed that the model developed in the study predicted the electric load in a building over one day with a mean average percentage error of 5.67%. It was also possible to see the advantages of dividing the prediction into smaller parts and testing different parameters for each hour that would be forecast.

With regard to comparisons with other studies and that residential buildings are a well-known difficult forecasting problem, the result should be considered as acceptable. Most indications show that the forecasting model is good enough to be able to assist a smart control of a battery in a building with useful information.

# INNEHÅLLSFÖRTECKNING

Förord.....	1
<b>1 INLEDNING.....</b>	<b>1</b>
1.1 Bakgrund.....	2
1.2 Syfte.....	2
1.3 Avgränsningar.....	2
<b>2. TEORI.....</b>	<b>3</b>
<b>2.1 Kortsiktig elektrisk lastprognostisering för byggnader.....</b>	<b>3</b>
2.1.1 Svårigheter med kortsiktig elektrisk lastprognostisering för byggnader.....	3
2.1.2 Karaktäristik av elektriska lastdata i byggnader.....	4
2.1.3 Inparameter.....	5
2.1.4 Enkelhet.....	6
<b>2.2 Vanligaste modellerna.....</b>	<b>7</b>
2.2.1 Statistisk regressionsmodell.....	7
2.2.2 Stödvektormaskin.....	7
2.2.3 Neurala nätverk.....	7
<b>2.2 Klustering.....</b>	<b>8</b>
2.2.1 K-mean kluster.....	8
<b>2.3 Neurala nätverk.....</b>	<b>10</b>
2.3.1 Struktur neurala nätverk.....	10
2.3.2 Träning av neurala nätverk.....	12
2.3.3 Utmaningar för neurala nätverk.....	13
<b>3 GENOMFÖRANDE.....</b>	<b>14</b>
3.1 Neurtalt nätverk.....	14
3.2 Kluster.....	15
3.3 Träning och testning.....	15
3.4 Varför neurala nätverk?.....	16
3.5 Motivering av val i modellen.....	16
<b>4 RESULTAT.....</b>	<b>18</b>
4.1 Utvärdering av prognostiseringsmodell.....	18
4.2 Utvärdering mellan olika försök.....	19
<b>5 DISKUSSION.....</b>	<b>20</b>
<b>6 SLUTSATS.....</b>	<b>22</b>



# 1 INLEDNING

Med bakgrund av att vi står inför stora klimatutmaningar har Europeiska Unionen satt upp tydliga klimatmål som innehåller specifikationer om att öka andelen energi från förnybara energikällor (Delreux & Ohler 2019). Elnätets krav på balans mellan elproduktion och elförbrukning vid varje tidpunkt innebär att icke-reglerbara energikällor likt sol- och vindkraft ökar behovet av reglerkraft. Därav finns det oftast begränsningar kring hur mycket som kan installeras av dessa energikällor (Notton et al. 2011).

Många studier tyder på att elbilars expansion på marknaden kommer att vara snabb (Gnann et al. 2018). En stor utmaning för elbilar är att det ska finnas tillräcklig energidensitet i batterierna. Vid användning av ett batteri minskar energilagringsskapaciteten, och förr eller senare kommer det vara aktuellt med att byta batterierna för att öka energilagringsskapaciteten (Dell, Moseley & Rand 2014). När batterierna ska bytas finns det en potential i att använda de uttjänta batterierna som batterilager i byggnader, där det inte finns samma krav på energidensitet. Därmed är det möjligt att vi i framtiden kommer ha byggnader med solceller på taket och batterilager i källaren. Har en byggnad denna uppsättning finns det möjligheter att styra batterilagret på ett smart sätt för att exempelvis optimera användandet av solenergin lokalt. Ett resultat av styrningen blir att mer solenergi kan installeras i distributionsnätet genom att en del av balanseringen mellan elproduktion och elförbrukning sker lokalt (McLoughlin & Conlon 2015). För att kunna styra batterilagret på ett smart sätt behöver styrningen få information om den förväntade elektriska lasten. Denna information går att få fram genom en prognostisering.

Prognostisering innebär att med statistiska eller analytiska tekniker utvecklar en modell som kan förutse framtida händelser eller beteenden (Nyce & Cpcu 2007). Prognostisering används inom allt ifrån aktiemarknaden till när Youtube rekommenderar dig en video (Covington, Adams & Sargin 2016). I ett distributionsnät är prognostisering av den elektriska lasten en viktig komponent för att kunna hålla balans mellan elproduktion och elförbrukning (Chen, Chen, Cui & Liu 2015). Ett förhållandevis nytt forskningsområde är att utföra prognostisering av den elektriska lasten i byggnader. I jämförelse med distributionsnäten är detta ett svårt prognostiseringsproblem, men i takt med en ökad mätning i elnät och hus och att prognostiseringsmodeller blir bättre börjar dessa prognoser bli intressanta. Största fördelen med att kunna prognostisera den elektriska lasten i en byggnad är att det möjliggör för att utföra balansering av elektrisk last och produktion på lokal nivå (Gerwig 2017).

## **1.1 Bakgrund**

Research Institutes of Sweden (RISE) är ett oberoende forskningsinstitut som spänner över många områden. En stor del av forskningen är projektbaserad och inom dessa projekt finns det oftast även andra aktörer som är verksamma inom branschen forskningen berör. Storleken på RISE:s roll i ett projekt kan variera. Denna studie är en del av ett större forskningsprojekt runt Brf Viva, kring hur framtidens boende kan se ut. Största aktören i projektet är Riksbyggen som är ett kooperativt företag som bygger och förvaltar bostäder. En del av projektet handlar om hur framtidens energiförsörjning av en byggnad kan se ut och huvudaktör inom detta område är Göteborgs Energi som är ett energibolag.

Projektets aktuella status är att nybyggda bostadsrättslägenheter står färdiga, dock har inte alla dessa lägenheter blivit tillträdade än. Byggnadernas energisystem innefattar: bergvärme, fjärrvärme, luftvärmepumpar, solceller och el från distributionsnät. Utöver detta finns det möjlighet att lagra varmvatten i ackumulatortankar och el i batterier. För att använda systemet på bästa möjliga sätt, och förhoppningsvis kunna se ekonomiska och miljömässiga fördelar, krävs det en smart styrning. RISE har fått i uppdrag att ge styrförslag till Brf Viva.

För att kunna utföra en bra styrning efter egna premisser behövs en föraning om hur den närliggande tiden kommer se ut. Några faktorer som är bra att ha information om i detta fall är el- och fjärrvärmepriser, förväntad solelproduktion och förväntad elektrisk och värmelast. Prognostiseringsmodellen som ska utvecklas i denna studie har i uppgift att mata styrningen med information på timbasis om hur den elektriska lasten i byggnaden förväntas se ut ett dygn framöver.

## **1.2 Syfte**

Syftet med denna studie har varit att utföra elektrisk lastprognostisering för en byggnad över ett dygn.

## **1.3 Avgränsningar**

Studien har inte för avsikt att utföra några omfattande försök till optimering av prognostieringsmodellen då det i många fall är avancerat och tidskrävande. På grund av tidsbrist har modellen inte testats hur den fungerar under helger. Studien gör inte några anspråk på att försöka lösa problem relaterat till dåliga data vid inläring eller drift av modellen.

## 2. TEORI

I detta avsnitt beskrivs utmaningar och vanliga tillvägagångssätt kring kortsiktig elektrisk lastprognostisering av byggnader. Inom elektrisk lastprognostisering används ofta neurala nätverk för att prognostisera och i vissa fall kluster för att automatisera val i modellen och dessa förklaras båda på ett generellt sätt och med exemplen av specifika neurala nätverk och klustren.

### 2.1 Kortsiktig elektrisk lastprognostisering för byggnader

Med kortsiktig elektrisk lastprognostisering av byggnader avses att göra en prognos av hur stor den elektriska lasten kommer vara i en byggnad. Definitionen av kortsiktig lastprognostisering går isär inom litteraturen, men oftast syftas det på en tidshorisont upp till ett par dagar. Det vanligaste är att tidshorisonten är ett dygn och granulariteten på datan brukar vara på timbasis (Hippert, Pedreira & Souza 2001). Det finns mycket forskning inom lastprognostisering, men förhållandevis lite om lastprognostisering av byggnader (Borges, Peña, Fernández, Prieto & Bretos 2013). Lastprognostisering används främst i större nät, likt regionnät, eftersom att det där är viktigt att ha balans mellan elproduktion och elförbrukning. Under senare år har nya smarta elmätare som ger mer detaljerade data gjort det enklare att utföra bra analyser av elektriska lastbeteenden i byggnader. Detta har bidragit till att utvecklingen av lastprognostisering av byggnader gått framåt, men det är fortfarande ett forskningsområde i utveckling (Jetcheva, Majidpour & Chen 2014). Vad som sticker ut vid lastprognostisering av byggnader i jämförelse med andra större system är att en enkel modell som fungerar på många olika byggnader ofta är att föredra. I de flesta fall behövs även en modell som är bra på att hantera lastmönster som är icke-linjära och som utvecklas över tid (Fernández, Borges & Peña 2011).

#### 2.1.1 Svårigheter med kortsiktig elektrisk lastprognostisering för byggnader

Det finns flertalet aspekter som gör lastprognostisering av en byggnad extra utmanande i jämförelse med till exempel i ett distributionsnät. En stor utmaning ligger i att alla byggnader är unika och att det ofta är brist på information om viktiga byggnadsparametrar. Några viktiga byggparametrar kan vara; byggmaterial, människors beteende i byggnaden, geografisk position (Rahman & Vega 2015). Även information om hur ventilation och uppvärmning fungerar i huset har avgörande betydelse för den elektriska lastförbrukningen (Borges et al. 2013). Eftersom många betydande byggparametrar inte tas hänsyn till leder det till att det kan vara svårt att använda samma modell på olika platser i världen med olika byggstandarder (Fahad & Arbab 2014). Integritetskränkning mot de boende kan leda till att viktiga parametrar inte är tillgängliga i bostadshus. Detta är en av anledningarna till att det inte har forskats mycket på den typen av byggnader. Ett annat skäl till bristen av forskning inom området är att bostäders elektriska lastförbrukning är starkt förknippad med när människorna är hemma, vilket innehåller stora variationer och leder till ett svårt prognostiserings problem (Rahman & Vega 2015).

Vid lastprognostisering är det viktigt att datan som används är av hög kvalitet. Datan behöver först och främst vara fullständig. Det är också viktigt i en inlärningsfas av modellen att inte ta hänsyn till kraftigt avvikande värden (s.k. outliers) då det leder till större fel i sina prognoser. Det är dock en utmaning att kunna avgöra om ett värde är kraftigt avvikande då det dynamiska intervall som lasten verkar inom varierar mycket mellan olika byggnader och mellan olika tidpunkter under veckan (Thokala, Bapna & Chandra 2018).

Med elektrisk lastprognostisering av byggnader är det ytterst svårt, om ens möjligt, att generellt säga vilken modell som är bäst. Det finns många anledningar till detta, till exempel olika preferenser, unika hus och det faktum att en modell som prognostiserar med hög träffsäkerhet i några hus kan misslyckas totalt i ett annat (Borges, Peña & Fernández 2011). Utöver detta finns det inget standardiserat sätt att testa precisionen i prognoserna, vilket leder till att många olika metoder används i studier (Liu, Wang & Ghadimi 2017).

### **2.1.2 Karaktäristik av elektriska lastdata i byggnader**

För att kunna göra en bra lastprognostisering behövs god kunskap om karaktäristiken på lasten som prognostiseras. Vid noggrann analys av lastmönstren går det att se att lastkurvan är periodisk. Det finns en stark korrelation mellan last och tid. Det går enkelt att se att det finns en periodicitet över en dag, men det finns även oftast en periodisk karaktär över veckan, årstider och år. Om det inte finns någon periodicitet i lasten försvårar det prognostiseringen avsevärt eftersom de flesta effektiva prognostiseringsmodeller bygger på att de periodiska mönstren ska fortsätta på liknande sätt (Fahad & Arbab 2014).

Den enskilt största faktor som påverkar lastkurvans form är typ av dag. Exempelvis skiljer sig lastkurvan en vardag mycket mot en helgdag. Är skillnaderna stora behövs dessa dagar hanteras separat för att kunna uppnå ett bra resultat. Det behövs en god kunskap om vilka dagar som har liknande lastkurvor för att kunna göra denna uppdelning. Ett alternativ är att hantera varje dag enskilt, detta leder dock till en mer komplicerad modell och behöver inte leda till bättre prognoser; framförallt när det är en modell som kräver mycket historiska data (Hippert, Pedreira & Souza 2001).

I regel är det alltid svårare att lastprognostisera ett mindre system än ett större (Fux, Benz, Ashouri & Guzzella 2013). Det finns alltid icke-lineariteter i laster; i större nät blir denna icke-linearitet mer sammanlagrad då förväntad last som inte förbrukas kompenseras av last som inte är förväntad. I byggnader blir det icke-linjära i lasten inte lika sammanlagrat och leder till större fluktuationer. En modell som ska prognostisera lasten i en byggnad behöver därav kunna hantera icke-linjära lastmönster vilket är en mer komplex prognostiseringsutmaning (Fernández, Borges & Peña 2011).

Det är viktigt att ha kunskap om prognostiseringsmodellen och om den behöver vara bra på att hantera plötsliga ändringar i lastmönster. Vissa enklare modeller kan prognostisera med goda resultat vid normala förhållanden men kan leda till stora fel vid en plötslig förändring i lastmönstret. Dessa förändringar kan till exempel bero på förändringar i vädret eller typ av dag. Då det i de flesta fall är fördelaktigt att ha en enkel modell bör behovet av en adaptiv prognostiseringsmodell undersökas innan val av modell (Raza & Khosravi 2015).

### **2.1.3 Inparameter**

Valet av inparametrar har en stor påverkan på en prognostiseringsmodells träffsäkerhet och funktion. Det är ofta en utmaning att göra detta val då det inte finns något generellt sätt att välja inparametrar. Det blir inte enklare av det faktum att korrelationen mellan en inparameter kan variera mycket mellan olika byggnader och under olika tidpunkter över dagen (Raza & Khosravi 2015). Denna variation går att se vid undersökning av utomhustemperaturens korrelation till den elektriska lasten. Under natten är det möjligt att utomhustemperaturen har en hög korrelation till den elektriska lasten, däremot under dagen kan det vara personers beteende i byggnaden som påverkar den elektriska lasten mer. Under en varm dag kommer byggnader som har luftkonditionering se stora skillnader i korrelation mellan utomhustemperaturen och den elektriska lasten gentemot en byggnad som inte har det. Att dessa korrelationer även ändrar sig över året gör det extra komplicerat (Jetcheva, Majidpour & Chen 2014). Därmed krävs det goda kunskaper om systemet som analyseras för att kunna se vilka faktorer som påverkar den elektriska lasten. Vad som försvårar valet av inparametrar ytterligare är att för många inparametrar kan leda till problem relaterat till komplexitet och för få kan leda till dålig träffsäkerhet (Hippert, Pedreira & Souza 2001).

Den viktigaste oberoende parametern för den elektriska lasten är vädret (Fahad & Arbab 2014). Det är ofta oväntade väderförändringar som ligger bakom felaktigheter i prognostiseringen. Sambandet mellan utomhustemperaturen och elförbrukningen är stark, men det är ett komplext samband. Till exempel om utomhustemperaturen är under 20 °C stiger elförbrukningen när temperaturen sjunker. Däremot om temperaturen är över 25 °C är det motsatt korrelation, elförbrukningen ökar när temperaturen höjs. Även luftfuktigheten spelar roll inom elförbrukningen eftersom människor inte kan känna vilken temperatur det är utan istället i vilken takt värme förs ifrån, eller till, kroppen. Detta är något som påverkas av just luftfuktigheten. Enligt Fahad och Arbab (2014) påverkas även elförbrukningen av nederbörd eftersom till exempel kraftigt regn kan leda till att folk stannar hemma och att det kan bli mörkare vilket bidrar till mer belysning.

En av de största faktorerna som påverkar den elektriska lasten i byggnader utöver vädret är människors beteende i byggnaden. Beteendet påverkar både användandet av elektrisk utrustning samt ventilation och klimatanläggningar. Det är en stor utmaning att prognostisera människors beteende med bra precision då det finns mycket variationer i beteendet. Informationen som behövs för prognostiseringen kan även vara svår att få tag på av integritetsskäl (Jones et al. 2012). På grund av dessa svårigheter är forskningen inom området fortfarande under utveckling och används inte i någon större grad än, trots att det finns en tydlig koppling till den elektriska lasten. De flesta modellerna är beroende av historiska lastdata där människors beteende bör märkas. Styrkan i att ha en prognos när människor är i huset är att beroendet av historiska lastdata minskar. Vid utveckling av en enkel modell som kan fungera på många byggnader kan det vara en fördel eftersom att det är möjligt att elektriska lastdata inte är tillgänglig (Sandels, Brodén, Widén, Nordström & Andersson 2016).

#### **2.1.4 Enkelhet**

Beroende på vad prognostiseringen ska användas till ställs olika krav på enkelheten av modellen. Det finns stora förhoppningar att elektrisk lastprognostisering av byggnader ska kunna vara en del av efterfrågad flexibilitet, vilket innebär att man försöker uppnå balans mellan elproduktion och elförbrukning genom att reglera lasten. Det kan också användas för att minska effektoppar och på så sätt kunna undvika eller senare lägga dyra utbyggnader av nätet (Bešli & Dağtekin 2015). Om efterfrågad flexibilitet ska få önskad effekt gäller det att den går att utföras i stor skala. Detta ställer stora krav på modellen i form av enkelhet. Ambitionen är att kunna använda modellen på många byggnader med minimal handpåläggning för att få ner kostnaderna. Först och främst är det viktigt att använda sig av förenklingar som leder till minskat behov av inparametrar då de kan vara svåra att få tag på. Därmed bör inparametrar hållas till ett minimum och att modellen tar hänsyn till hur enkelt det är att få data till inparametrarna. Det är även viktigt att uppskattningar av parametrar och antaganden i modellen minimeras, något som är ytterst vanligt inom elektrisk lastprediktering av byggnader då de flesta byggnader är unika. Förenklingarna som krävs för en modell i stor skala leder i många fall till sämre precision i prognostiseringen. Detta leder till att ett ställningstagande behövs göras i konflikten mellan vilken precision som är godtagbar för ens modell gentemot hur generell och enkel modellen bör vara. I denna ekvation behövs det även ta hänsyn till kostnader då mer komplicerade och alternativt flertalet mindre generella modeller även kommer med en högre kostnad (Fahad & Arbab 2014).

Ett vanligt tillvägagångssätt är att göra en stor komplex modell som tar hand om hela prognostiseringsutmaningen. Ett alternativt sätt att ta sig an uppgiften är att dela upp problemet i flertalet små problem där lösningen blir mindre komplex. Vid stora komplexa problem kan detta vara en framgångsrik metod och gör i många fall modellens struktur enklare (Jetcheva, Majidpour & Chen 2014).

## 2.2 Vanligaste modellerna

En prognostiseringsmodell kan ha många olika former. När det handlar om byggnaders elektriska last är det vanligast att prognostiseringen bygger på antingen en statistisk regressionsmodell, stödvektormaskin (SVM) eller neurala nätverk (NN). Det finns även många varianter och kombinationer av dessa eller andra metoder för att uppnå bättre resultat (Zhao & Magoulès 2012). Nedan följer en sammanfattning av de vanligaste modellerna.

### 2.2.1 Statistisk regressionsmodell

Statistiska regressionsmodeller använder sig av tidsserier för att göra en prognos av hur framtiden kommer se ut. Således använder statistiska modeller enbart historiska data. Fördelarna med en statistisk modell är att de har en förhållandevis enkel struktur och lätt att använda (Zhao & Magoulès 2012). De största nackdelarna däremot är att de har svårt att hantera icke-linearitet i den historiska lastdatan (Jones et al. 2012), vilket finns mycket i byggnader, och att de i många fall får en kraftigt försämrad prognos vid plötsliga ändringar i det elektriska lastmönstret (Raza & Khosravi 2015).

### 2.2.2 Stödvektormaskin

En stödvektormaskin är en maskininlärningsmodell som lär sig av sina misstag och kan lösa icke-linjära problem genom att skapa ett eller flera hyperplan som sedan används vid exempelvis regression (Borges, Peña & Fernández 2011). Ett n-dimensionellt rum har ett hyperplan som är ett rum med en lägre dimension (Towards Data Science 2019). Fördelen med SVM är att på grund av hyperplanen går det att använda linjära beräkningsmetoder trots att mönstren i den aktuella datan är icke-linjär (Hofmann, Schölkopf & Smola 2008). De linjära beräkningsmetoderna gör att SVM kan lösa icke-linjära problem med förhållandevis lite historiska data (Zhao & Magoulès 2012). Andra styrkor med modellen ligger i att det är en effektiv, robust och träffsäker modell som inte är känslig för om inkommande data är kraftigt avvikande. Dock är SVM känslig för plötsliga stående ändringar i det elektriska lastmönstret (Rahman & Vega 2015).

### 2.2.3 Neurala nätverk

Neurala nätverk (NN) är en maskininlärningsmodell som försöker efterlikna hur den mänskliga hjärnan lär sig saker genom att bearbeta mycket information. NN har fått mycket uppmärksamhet då det anses vara ett kraftfullt verktyg för att lösa komplexa problem (Raza & Khosravi 2015). Eftersom elektrisk lastprognostisering av byggnader är ett komplext icke-linjärt problem har NN blivit en populär och vanligt förekommande modell att använda (Rahman & Vega 2015). En annan fördel med NN är att modellen inte är beroende av mänsklig expertis utan lär sig komplexa samband på egen hand genom inläring (Raza & Khosravi 2015). Samtidigt som neurala nätverk kommer med stor potential om träffsäkra prognoser och en adaptiv modell, medföljer även flertalet utmaningar. För det första erfordrar ett neuralt nätverk många svåra val av parametrar under skapandet i kombination med att det är svårt att veta om ett inlärt neuralt nätverk är det bästa tänkbara. Sedan kräver även modellen mycket historiska data för att kunna lära sig mönster i datan och kräver ofta en stor beräkningsmängd (Jetcheva, Majidpour & Chen 2014). En av anledningarna till att neurala nätverk fått ett ökat intresse på senare år är att det numera går att använda molnbaserade lösningar för sina beräkningar, vilket

gör att det inte finns samma behov av en egen kraftfull server (Luo, Small, Dugan & Lane 2019). Mer ingående beskrivning om NN finns i stycke 2.3.

Vid val av prognostiseringsmodell är det inte enbart precisionen i prognosen som tas i beaktande, utan även en sådan sak som hur lätt modellen är att använda kan spela en avgörande roll. Modellerna visar stora skillnader i precision, körhastighet, komplexitet och enkelheten att använda, se Tabell 1 (Zhao & Magoulès 2012).

Tabell 1. Jämförelse mellan statistisk modell, stödvektormaskin (SVM) och neurala nätverk (Zhao & Magoulès 2012).

Metod	Modell komplexitet	Enkel att använda	Körhastighet	Träffsäkerhet
Statistisk modell	Okej	Ja	Ganska snabb	Okej
SVM	Ganska hög	Nej	Långsam	Ganska hög
Neurala nätverk	Hög	Nej	Snabb	Hög

## 2.2 Klustering

Klustringens uppgift är att gruppera ett antal objekt på sådant sätt att liknande objekt hamnar i samma kluster. Det används exempelvis vid bildigenkänning när modellen ska lära att se skillnad på en katt och en hund till exempel (Ramchoun, Idrissi, Ghanous & Ettaouil 2016). Detta är en maskininlärningsmetod som bygger på oövervakad inlärning, vilket betyder att det inte finns ett rätt svar att förhålla sig till innan klustringen är utförd, vilket finns vid övervakad inlärning (Celebi, Kingravi & Vela 2013). Klustering kan användas som ett verktyg för att välja ut indata till en prognostiseringsmodell. Att använda klustering för att välja indata kan öka träffsäkerheten i prognostisering främst eftersom det är svårt att välja indata på teoretisk grund (Jetcheva, Majidpour & Chen 2014).


### 2.2.1 K-mean kluster

K-mean kluster är den vanligaste klustersalgoritmen för uppdelning av objekt i grupper. Antal kluster (k-värdet) är ett fast värde som har bestämts innan klustringen genomförs. Varje kluster har en centroid som oftast är ett medelvärde av alla objekt i klustret (Celebi, Kingravi & Vela 2013). Den enklaste formen av ett K-mean kluster grupperar ett antal objekt enligt följande steg (Wang, Wang & Jiang 2013):


1. De initiala centroiderna får en slumpmässig placering.
2. Objekten kopplas ihop med den centroid som befinner sig närmast.
3. Centroiderna ändrar sin position till mittpunkten av de objekt som ingår i klustret.
4. Objekten kopplas på nytt ihop med den centroid som befinner sig närmast.
5. Centroiderna ändrar sin position på nytt och detta upprepas tills objekten slutar att byta kluster.

Ett k-mean kluster är mycket känsligt för den initiala placeringen av centroiderna. Det beror på att ett k-mean kluster fungerar på sådant sätt att den gradvis går mot en lägre feldifferens, kortare totaldistans mellan objekt och centroider, och kan därför fastna i lokala minimumpunkter istället för globala. Det finns många olika metoder för att lösa detta problem, dock är det inget enkelt val att välja rätt metod (Celebi, Kingravi & Vela 2013).

Klustring går att göra i flera dimensioner. I Figur 1 går det att se hur ett endimensionellt kluster kan se ut enbart baserat på elektrisk last med ett k-värde lika med fem. I Figur 2 visas ett tvådimensionellt kluster baserat på elektrisk last och utomhustemperatur med normaliserade data.



Figur 1. Ett exempel på hur ett kluster baserat på elektrisk last kan gruppera olika timmar. Timmarna i ett kluster behöver inte ligga bredvid varandra tidsmässigt, detta är enbart för att visa en tydligare figur.



Figur 2. Ett exempel på hur ett dygns timmar kan klustras baserat på elektrisk last och temperatur med normaliserade data. Prickarna med samma färg ingår i samma kluster och krysset är dess centroid.

Beroende på vad klusteralgoritmen ska användas till kan valet av antal kluster ha stor påverkan på resultatet. I en situation då det inte finns något givet  $k$ -värde (antal kluster) är det svårt att komma fram till hur många kluster som är bäst rent intuitivt. Det finns metoder som kan hjälpa till i valet, men det vanligaste är att testa sig fram (Datanovia 2018). Genom normalisering av datan undviks att exempelvis ett tvådimensionellt kluster beror dominerande av värdemängden på grund av värdemängden sträcker sig över ett mycket större intervall än definitionsmängden. Normalisering leder också till ökad precision och snabbhet i klusteralgoritmen (Mohammad & Usman 2013).

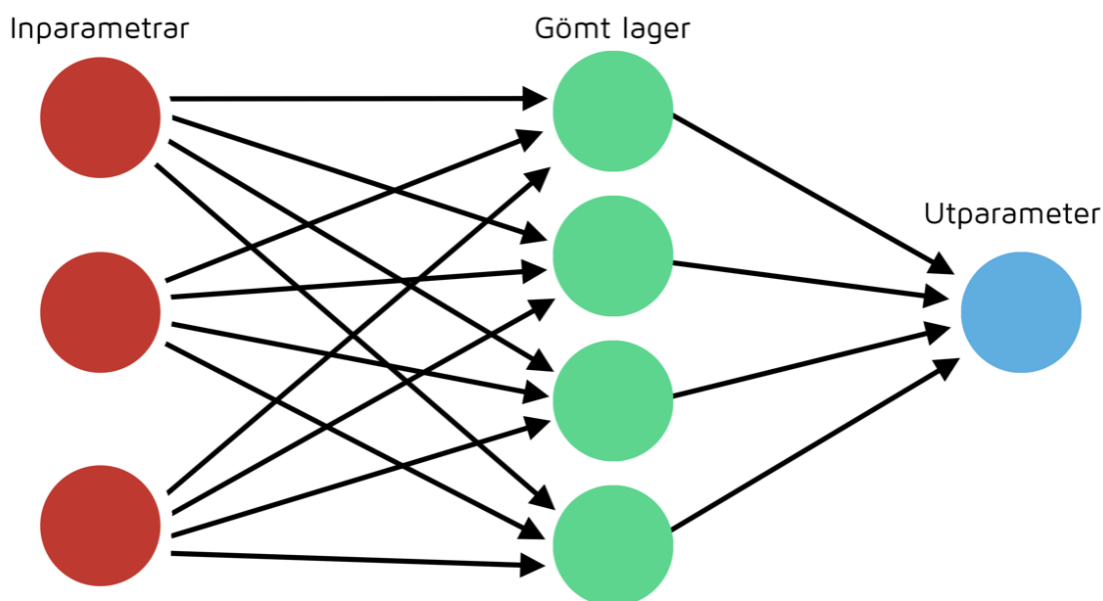
## **2.3 Neurala nätverk**

Neurala nätverk är en maskininlärningsalgoritm som kan användas till både klassifikations- och regressionsproblem vid exempelvis bild- och mönsterigenkänning (Ramchoun, Idrissi, Ghanous & Ettaouil 2016). Prognostisering är ett typiskt regressionsproblem, därav kommer fokus ligga på det i denna teoridel. Till skillnad från klustring bygger neurala nätverk på övervakad inläring. Det innebär att för varje indatasekvens känner man till den korrekta utdatasekvensen. Därmed kan det neurala nätverket tränas och lära sig vilken specifik utdatasekvens som ska genereras vid varje godtycklig indatasekvens (Raza & Khosravi 2015).

### **2.3.1 Struktur neurala nätverk**

Den slutliga strukturen av ett neuralt nätverk är sällan uppenbart. Ett vanligt tillvägagångssätt är att börja med en förhållandevis enkel struktur och sedan testa sig fram med mer komplexa strukturer (Jetcheva, Majidpour & Chen 2014). Topologin i ett neuralt nätverk kan se ut på många olika sätt. Topologin som är i fokus för den här rapporten är ett multilayer perceptron (MLP) nätverk med backpropagation (BP). När neurala nätverk nämns eller diskuteras i rapporten är det denna struktur på det neurala nätverket som åsyftas. Förklaring av MLP och BP ges i stycke 2.3.2.

Neurala nätverk består av  $x$ -antal lager. Ett neuralt nätverk med en enkel struktur går att se i Figur 3. Alla cirklar i figuren kallas för neuroner och består av en typ av vikt som kallas för bias. I neuronerna processas informationen som kommer in innan den skickas vidare. Pilarna kallas för synapser, likt i den mänskliga hjärnan, och består av vikter. Det neurala nätverket som går att se i Figur 3 har tre inparametrar som alltid är sammankopplade med alla neuroner i nästa lager, i detta fall ett gömt lager. Data skickas sedan från det gömda lagret till utparametern där resultatet sammanställs. Det absolut enklaste neurala nätverket består av enbart en in- och en utparameter, utan något gömt lager. De gömda lagerna är alla lager mellan in- och utparametrarna. Det finns dock inga gränser för hur stort ett neuralt nätverk kan vara. För att kunna lösa icke-linjära problem krävs det att det neurala nätverket har minst ett gömt lager (Raza & Khosravi 2015).




Figur 3. Ett exempel på en enkel struktur i ett neuralt nätverk.

I en neuron sammanställs summan av alla indata från synapserna och lägger till neuronens bias, enligt ekvation:

$$x = \sum(\text{inputparameter} * \text{vikt}) + \text{bias} . \quad (1)$$

En aktiveringsfunktion bedömer x-värdet och bestämmer vad utdatan från neuronerna ska bli. Aktiveringsfunktioner kan fungera på många olika sätt. En vanlig aktiveringsfunktion för neurala nätverk som används för regression är rectified linear unit (ReLU). Om x-värdet är under 0 genererar ReLU utdatan 0. Vid ett x-värde över 0 är x-värdet lika med utdatan, se Figur 4 (Lin & Shen 2018).



Figur 4. ReLU aktiveringsfunktion.

Utdata från neuronerna blir indata till nästa synaps och detta fortsätter tills det kommer till det sista lagret som är utparametrar (Becoming human 2017). Valet av aktiveringsfunktion är sällan uppenbart och sker i många fall genom att testa sig fram (Raza & Khosravi 2015).

### 2.3.2 Träning av neurala nätverk

Träningsfasen av ett neuralt nätverk är en process då synapsernas vikter och neuronernas biases ska justeras för att få minimal skillnad mellan nätverkets utdata och den önskade utdatan. På detta sätt lär sig modellen de komplexa sambanden mellan in- och utparametrarna. De initiala vikterna på synapserna har ingen koppling till träningsdatan utan tilldelas oftast genom statistisk distribution. En enkel metod är att alla vikter börjar på 1, men en vanligare metod är att använda sig av normal distribution (Keras 2019). Senare vid testning med inparametrar från historiska data på det neurala nätverket kommer utdatan förmodligen ligga långt ifrån den historiska utdata som siktades på (Ramchoun et al. 2016). Under träning används en optimeringsalgoritm som kontinuerligt beräknar felmarginalen via en felfunktion och sedan uppdaterar synapsernas vikter och neuronernas bias gradvis för att minska felmarginalen vid nästa iteration till dess att det globala minimumet för felmarginalen har uppnåtts (Machine learning mastery 2019). Hur stora uppdateringarna ska vara bestäms av en förutbestämd inlärningstakt. Adaptive gradient (AdaGrad) är en optimeringsalgoritm som har en anpassningsbar inlärningstakt och är följaktligen inte lika känslig för val av inlärningstakt (Hadgu, Nigam & Diaz-Aviles 2015). Ett sätt att räkna ut felmarginalen är genom mean absolute percentage error (MAPE) som beräknar genomsnittet av absolutbeloppet av de procentuella felen, se matematisk beskrivning i ekvationen: (De Myttenaere, Golden, Le Grand & Rossi 2016).

$$felmarginal = \frac{1}{n} \sum_{t=1}^n \left| \frac{V - \bar{V}}{V} \right|. \quad (2)$$

I (2) är felmarginalen i procent,  $V$  det faktiska värdet och  $\bar{V}$  det prognostiserade värdet.

Om optimeringsalgoritmen under träningsfasen är baserad på backpropagation betyder det att algoritmen arbetar från felmarginalen vid utdatan genom nätverket tillbaka till inparametrarna och korrigerar synapsernas vikter längs vägen. Neurala MLP nätverk med BP är populära på grund av deras förhållandevis enkla topologi och välkända optimeringsalgoritmer (Kazmierkowski, Krishnan, Blaabjerg & Irwin 2002).

Träningsdatan består av  $x$ -antal träningsexemplen där relationerna mellan in- och utparametrar är kända och kommer ifrån historiska data. I många fall är det nödvändigt att förbehandla träningsdatan för att både få en snabbare träningsfas och bättre prognostiseringsmodell. Ett vanligt sätt att göra det på är att skala datan mellan 0 till 1 (Kuźniar & Zajac 2017). Att använda all träningsdata en gång kallas för en epok. Träningsdatan används upprepade gånger på nätverket till dess att synapsernas vikter är bestämda. Det går dock att köra en hel epok innan uppdatering av vikterna, vilket oftast ger den mest träffsäkra modellen, men detta ger också en beräkningsmängd som blir mer krävande och i flera fall inte är möjlig på grund av begränsningar i datorkapacitet. En lösning på detta problem är att dela upp träningsdatan i mindre delar som kallas för batches, där synapsernas vikter och neuronernas biases istället uppdateras efter varje batch (Radiuk 2017).

Under valideringsfasen testas hur bra modellen presterar på data som inte varit inkluderad i träningsfasen och det avgör när träningen ska avslutas för att undvika överanpassning vilket försämrar modellen. Mer detaljerad beskrivning om överanpassning kommer i näst följande

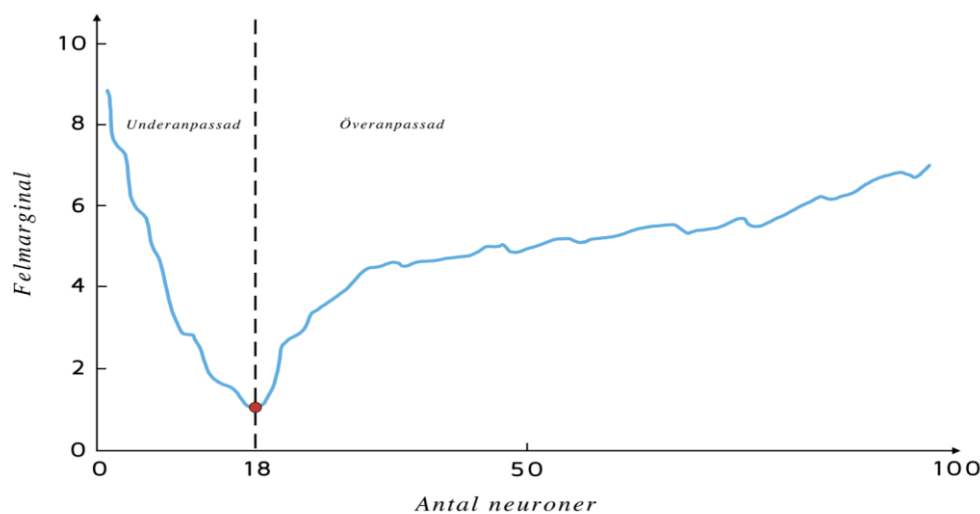
stycke. När träningsfasen är avslutad utvärderas nätverket genom att testa modellen med testdata som inte varit en del av tränings- eller valideringsdatan (Chiang, Chang & Chang 2004).

### 2.3.3 Utmaningar för neurala nätverk

Det händer att NN hittar ett lokalt minimum under inlärningsfasen som misstas för ett globalt minimum. Ett lokalt minimum medför en sämre precision för modellen och det kan även bli svårt att upptäcka att detta har hänt. Problem med lokala minimum ökar med en mer komplex struktur i ett neuralt nätverk (Omidvar & Dayhoff 1997). Metoderna som används för att undvika att det neurala nätverket fastnar i ett lokalt minimum leder i många fall till tidskrävande och beräkningstunga modeller då de kan kräva tusentals epoker under träningsfasen (Kazmierkowski, Krishnan, Blaabjerg & Irwin 2002).

En stor nackdel med neurala nätverk är att utvecklaren ställs inför många val angående till exempel: topologidesign, felfunktion och optimerings algoritm vid inläring för att nämna några. I många fall görs dessa val genom att testa sig fram på ett heuristiskt vis utan vidare vetenskap om de bästa valen görs (Kazmierkowski, Krishnan, Blaabjerg & Irwin 2002).

Ett neuralt nätverks uppgift är att skapa den bästa tänkbara generella modellen. För att den ska vara generell måste den lära sig känna igen mönster i träningsdatan. En för enkel struktur i det neurala nätverket eller för lite träningsdata kan leda till att modellen inte lyckas lära sig dessa mönster. Detta fenomenet kallas för underanpassning. Det är även dåligt om nätverket blir överanpassat till träningsdatan. Istället för att nätverket enbart innehåller generella mönster från träningsdatan börjar nätverket även inkludera slumpmässiga avvikande värden i strukturen, vilket resulterar i en modell som prognostiserar sämre med data som inte ingår i träningsdatan. Överanpassning kan antingen bero på att träningsfasen höll på för länge eller på grund av en för komplex nätverksstruktur (Hippert, Pedreira & Souza 2001). Vid skapandet av ett neuralt nätverk är det viktigt att fokusera på hur komplex strukturen ska vara för att uppnå bäst resultat, vilket går att se i ett test som utfördes i Liu, Wang och Ghadimi (2017) vars resultat går att tyda i Figur 5.



Figur 5. Test i Liu, Wang och Ghadimi (2017) som visar på vikten av att undvika under- och överanpassning för felmarginalen för prognostiseringen som är beräknad med MAPE.

### 3 GENOMFÖRANDE


Detta kapitel beskriver hur arbetet har gått till för att utveckla en elektrisk lastprognostiseringsmodell för en byggnad som kan ge prognoser över ett dygn. Lägenhetshuset som är i fokus för forskningsprojektet är inte fullt tillträtt än vilket gör att lastprofilen ändrar sig mycket över tid och gör det svårt att prognostisera. Därför används data ifrån ett annat lägenhetshus i Göteborgsregionen med närmare 500 studentbostäder i denna studie.

Prognostiseringsmodellen som är utvecklad i detta projekt är baserad på modellen som presenteras i Jetcheva, Majidpour och Chen (2014). Den bygger på ett neuralt nätverk med en klusteralgoritm som automatiserar delar av val av inparametrar och träningsdata genom att testa ett flertal neurala nätverk parallellt. Modellen är uppdelad i två delar med en modell som är utformad för vardagar och en för helgdagar. Båda modellerna ser likadana ut men använder olika data. På grund av tidsbrist finns det inga tester med helgdata. Modellen är utvecklad i Python med maskininlärningsbiblioteket Keras.

#### 3.1 Neuralt nätverk

I stället för ett enda stort neuralt nätverk som ska prognostisera är modellen uppdelad i 24 mindre nätverk, en för varje timma över dygnet. Flera neurala nätverk med olika inparametrar och träningsdata testas parallellt innan de modeller som presterar bäst för varje timma väljs ut. Förutom vilka inparametrar och träningsdata som används har alla neurala nätverk samma struktur.

Det neurala nätverk som används har en MLP struktur med BP som beskrivs i stycke 2.31. Inparametrarna består antingen av timvärden av det senaste dygnets elektriska last och utomhustemperatur eller enbart den elektriska lasten för de senaste 24 timmarna. Nätverket har ett gömt lager med tio neuroner och en utparameter som är den förväntade lasten den timman, se Figur 6.



Figur 6. Figuren visar strukturen på de neurala nätverk som används i modellen.

De initiala värdena på synapsernas vikter och neuronernas biases fördelas genom normal distribution. Aktiveringsfunktionen i nätverket är rectified linear unit (ReLU). Optimeringsalgoritmen som används under träning är adaptive gradient (AdaGrad) tillsammans med en mean absolute percentage error (MAPE) funktion för att beräkna felmarginal.

### 3.2 Kluster

Klustret som används är ett K-mean kluster. Det görs två kluster med timvärden över ett dygn. Det första är baserad på elektrisk last och utomhustemperatur och det andra enbart på den elektriska lasten.

För att underlätta och öka snabbheten i klustringen skalas den data som används. Istället för att välja hur många kluster som ska klustras testas alla möjliga nivåer, från 1 till 24 stycken. De kluster som exempelvis innehåller timma tre tränar sedan upp varsitt neuralt nätverk med träningsdata som innehåller träningsexemplen från alla timmar som ingår i klustret. Innan träningen börjar undersöks det om det finns några kluster som är identiska för att undvika onödig beräkningsmängd.

### 3.3 Träning och testning

De kluster som är baserade på elektrisk last och utomhustemperatur tränar även ett neuralt nätverk med de inparametrarna, motsvarande gäller för de kluster som enbart beror på elektrisk last. Den historiska datan är uppdelad i tre olika delar för: 1. Träning 2. Validering och 3. Test. De neurala nätverken tränas med 35 dagar av historiska data som är uppdelad i tränings- och valideringsdata. 80% av den historiska datan är för träning och 20% för validering. Valideringsdatan är slumpmässigt utplockade från den historiska datan. Valideringsdata innehåller valideringsexemplen från alla timmar som ingår i klustret för att kunna förhindra problem med överanpassning genom att avsluta inlärningen. Testdata däremot innehåller endast testexemplen från den specifika timma det neurala nätverket ska användas för att prognostisera. Alla neurala nätverk som ska prognostisera en viss timma testas med testdata som är frångående från tränings- och valideringsdatan. I modellen har testdatan bestått av tio dagar. Det testas enbart på testexempel där det finns data ett helt dygn innan prognostiseringstillfället. För varje timma över dygnet väljs det neurala nätverk ut som har minst felmarginal vid testning för att vara en del av prognostiseringsmodellen. Proceduren med inlärning och val av neurala nätverk är tänkt att upprepas ungefär var sjätte vecka. Därefter görs det ett test med hur inparametrarna kan se ut i drift. I och med att modellen består av 24 neurala nätverk, kommer de olika nätverken sakna allt ifrån 1 – 24 timmar innan den timma som ska prognostiseras vid varje prognostisering. Vid inlärning av ett neuralt nätverk som ska prognostisera timma sju har inparameter ett innehållit data ifrån timma sex, inparameter två ifrån timma fem och så vidare. Saknas data från timma sex används data från samma timma föregående liknande dag, vardag eller helg, och används som inparameter ett. Testet vid drift undersöker hur bra nätverken i genomsnitt fungerar i vanlig drift när data saknas mellan 1 till 24 timmar innan den timma som ska prognostiseras. Testdata som används för att testa hur bra nätverken fungerar i drift kommer ifrån samma tio dagar som används för att testa nätverken med aktuella data.

### 3.4 Varför neurala nätverk?

Enkelhet är ett ledord inom elektrisk lastprediktering av byggnader. En avancerad modell som är tidskrävande att utveckla och implementera är sällan ekonomiskt försvarbar. Målet är att utveckla en modell som fungerar på många byggnader med minimal handpåläggning vid implementering. Detta kan visa sig vara enklare sagt än gjort eftersom byggnader kan skilja sig åt väsentligt i lastprofil. En grundregel för att göra en enkel och generell modell är att minimera antalet inparametrar eftersom de kan saknas i vissa byggnader, därför bygger modellen enbart på historiska elektriska lastdata och utomhustemperatur.

En byggnad är ett litet system, därav bör det finnas slumpmässiga variationer i lastdata. Det är viktigt att den framtagna modellen inte tar hänsyn till sådana variationer, vilka innebär att modellen överanpassas till träningsdatan, utan istället enbart bygger på de generella trenderna i träningsdata för att öka träffsäkerheten. Vid problem med detta är lösningen att göra modellen enklare. En fördel med neurala nätverk är att det snabbt och enkelt går att göra modellen enklare, eller mer komplex, genom att ändra antalet neuroner och gömda lager.

Inom elektrisk lastprognostisering av byggnader är det många modeller som har problem med plötsliga förändringar i den elektriska lasten. För ett lägenhetshus kan en sådan förändring vara om någon köper en elbil. Det köpet kan påverka grannar att också köpa en elbil och bidra till att det kan uppstå en stor skillnad i den elektriska lasten för byggnaden (Grinblatt, Keloharju & Ikäheimo 2008). Neurala nätverk däremot är förhållandevis bra på att hantera dessa förändringar i lasten.

En fördel med neurala nätverk är att de ofta lyckas med en hög träffsäkerhet vid komplicerade prognostiseringsproblemen, men nackdelen är att de lätt blir komplicerade och beräkningstunga. Det vanligaste sättet att hantera ett prognostiseringsproblem är att lösa det med en modell. Ett alternativt sätt som används i modellen är att dela upp prognostiseringsproblemet i mindre delar. Det har gjorts genom att skapa en prognostiseringsmodell för varje timma under dygnet. Detta leder till att strukturen i de neurala nätverken blir enklare. Trots att det blir 24 modeller istället för en kan beräkningsmängden minska betydligt. Utöver detta minskar i många fall vanliga problem med neurala nätverk som lokala minimumproblem, över- och underanpassning med en enklare struktur (Jetcheva, Majidpour & Chen 2014).

### 3.5 Motivering av val i modellen

Följande val har baserats på val och tester som gjorts i Jetcheva, Majidpour och Chen (2014): multilayer perceptron nätverk med backpropagation, MAPE felfunktion, 35 dagar träningsdata, ett gömt lager med tio neuroner, att inlärningen av de neurala nätverken upprepas var sjätte vecka och att inparametrarna består av ett dygn timdata med elektrisk last och utomhustemperatur. MAPE valdes för att kunna jämföra resultaten med nämnda studie. Testerna i Jetcheva, Majidpour och Chen (2014) visade att i de flesta fall blir inte prognostiseringen nämnvärt bättre med träningsdata som överstiger 35 dagar. Det visades även att ha inparametrar från längre än ett dygn i vissa fall gav en bättre träffsäkerhet, men i andra

sämre. Strukturen i det neurala nätverket testades och visade att ett gömt lager fungerar bäst vid denna typ av prognostisering.

Många val kring maskininlärning är svåra att göra och kräver ofta omfattande tester för att komma fram till det optimala valet. AdaGrad valdes som optimeringsalgoritm eftersom det bidrar till en enklare modell då inlärningstakten inte behöver bestämmas manuellt och konvergerar i många fall snabbt (Hadgu, Nigam & Diaz-Aviles 2015). ReLU användes eftersom det är den vanligaste aktiveringsfunktionen och konvergerar snabbt (Lin & Shen 2018). Klustringen gjordes med K-mean eftersom det är den vanligaste klustringsalgoritmen (Celebi, Kingravi & Vela 2013).

Det är viktigt för en prognostiseringsmodells träffsäkerhet och funktion att välja de inparametrarna som har starkast korrelation till den elektriska lasten. Det behövs ofta mycket kunskap om systemet som ska prognostiseras för att veta vilka faktorer som korrelerar med den elektriska lasten mest. En fördel med en mindre beräkningstung modell är att det är enklare att testa olika inparametrar och se vilken som prognostiserar med högst träffsäkerhet innan det bestäms vilken som ska användas. Faktumet att korrelationen mellan olika faktorer varierar över olika tidpunkter under dagen talar än mer för att det är fördelaktigt att dela upp prognostiseringsmodellen i mindre delar. Vad som har inverkan på den elektriska lasten ändras även över tid, där av behöver modellen tränas upp på nytt med jämna mellanrum. En metodik där inparametrarna testas med jämna mellanrum och väljer ut de som bidrar till högst träffsäkerhet i prognoserna leder till att det är större chans att få fram en enklare modell. En enklare modell kan innebära färre inparametrar och leda till en modell som är snabbare och mer träffsäker.

Ett neuralt nätverk behöver många träningsexempel för att lära sig trender och samband i träningsdatan. Detta leder ofta till att träningsexemplen är förhållandevis gamla. I och med att korrelationerna mellan faktorerna som påverkar lasten varierar över tid kan detta innebära problem. Modellen som presenteras i denna studie löser detta problemet genom att om nätverket ska lära sig hur det fungerar vid timma 2, då går det att exempelvis testa att även använda träningsexemplen från timma 1 och 3 om de visar liknande karaktär. Klustringens uppgift är att para ihop de timmar som just har liknande karaktär. På detta sätt kan nätverket få tillräckligt med träningsdata men med nyare träningsexemplen.

Anledningen till att testen av de neurala nätverken baseras på aktuella data istället för driftdata beror på att nätverken är inlärd med aktuella data och ett test med sådan bör visa vilket nätverk som lärt korrelationerna mellan in- och utparametrar bäst. Det finns enstaka fall då nätverk presterar bättre med driftdata än aktuella data. Beskrivning av skillnad mellan driftdata och aktuella data finns i stycke 3.3. Eftersom nätverket inte har tränats med någon äldre data som används vid drift bör nätverk som presterar bättre med driftdata ses som slumpmässiga utfall.

## 4 RESULTAT

I detta kapitel redogörs resultaten från utvärdering av prognostiseringsmodellen.

### 4.1 Utvärdering av prognostiseringsmodell

Prognostiseringsmodellen utvärderas på samma sätt som när modellen väljer ut de neurala nätverken som ska användas för varje timma. I Tabell 2 går det att se vilken felmarginal de valda neurala nätverken har för varje timma i test och drift. Det går även att se vilka träningsdata och inparametrar som har använts för nätverket.

Tabell 2. Tabellen visar ett exempel på hur de valda neurala nätverken vid varje timma presterar både i test och drift. Samt vilka timmar som är med i träningsdatan och vilka inparametrar som användes.

Timma	MAPE test [%]	MAPE i drift [%]	Träningsdata	Inparametrar
0	4.24	6.87	0, 6	Elektrisk last
1	4.56	7.07	1, 6	Elektrisk last
2	4.25	6.63	0 – 23	Elektrisk last & temperatur
3	4.10	5.61	0 – 23	Elektrisk last & temperatur
4	3.14	5.26	0 – 23	Elektrisk last & temperatur
5	4.30	5.07	5, 6	Elektrisk last & temperatur
6	2.85	3.25	0 – 9	Elektrisk last & temperatur
7	3.31	4.44	7 – 10	Elektrisk last & temperatur
8	3.49	4.33	7, 8	Elektrisk last & temperatur
9	4.80	6.05	7 – 9	Elektrisk last & temperatur
10	7.59	8.35	0 – 23	Elektrisk last
11	4.64	7.30	0 – 23	Elektrisk last & temperatur
12	5.25	5.24	12, 13, 14, 16	Elektrisk last
13	4.74	4.99	0 – 23	Elektrisk last
14	5.13	6.48	0 – 23	Elektrisk last
15	2.98	4.42	12, 13, 15, 16	Elektrisk last
16	4.89	4.74	12 – 16	Elektrisk last & temperatur
17	4.83	4.64	17	Elektrisk last
18	5.69	6.07	18 – 21	Elektrisk last & temperatur
19	5.30	6.65	19	Elektrisk last & temperatur
20	5.88	8.74	0 – 23	Elektrisk last
21	4.74	5.98	11 – 23	Elektrisk last & temperatur
22	4.08	4.87	22	Elektrisk last & temperatur
23	2.11	3.07	12 – 16, 23	Elektrisk last

MAPE vid test över ett dygn: 4.45%

MAPE vid drift över ett dygn: 5.67%

Resultaten av utvärderingen i Tabell 2 visade att antal timmar som används till träningsdata varierar mycket under dagen, allt ifrån enbart den specifika timmen som ska prognostiseras till alla timmar över dygnet. Som inparameter använde 10 av nätverken enbart elektrisk last och 14 nätverk elektrisk last och temperatur. Den svåraste timman att prognostisera visade sig vara timma 10 och den enklaste timma 23 med en felmarginaldifferens vid test på 5.48%. I testet prognostiserade modellen i verklig drift med en felmarginal på 5.67%. Hela proceduren med inläring och testning av de neurala nätverken tog 28 minuter och 56 sekunder med en Macbook Pro (2.7 GHz processor med 8 GB minne).

## 4.2 Utvärdering mellan olika försök

Timma 9 med elektrisk last och utomhustemperatur som inparametrar testades fem gånger. Efter parallell klustring och borttagande av identiska kluster var det sju neurala nätverk som tränades med olika träningsdata. Testets resultat går att se i Tabell 3.

Tabell 3. Tabellen visar variationer i prestanda mellan fem olika försök för sju neurala nätverk med MAPE i test med aktuella data och driftdata. De fetstilta siffrorna visar det bästa neurala nätverket per försök.

Träningsdata	Försök 1	Försök 2	Försök 3	Försök 4	Försök 5
9	5.70 / 5.86 %	5.21 / 5.61 %	5.13 / 5.50 %	5.26 / 5.59 %	5.50 / 5.75 %
7 – 9	5.50 / 5.89 %	<b>5.08</b> / 5.37 %	5.81 / 6.02 %	<b>5.06</b> / 5.28 %	<b>5.10</b> / 5.77 %
6 – 9	5.80 / 5.51 %	5.15 / 5.61 %	5.45 / 5.80 %	5.38 / 6.11 %	7.28 / 8.34 %
6 – 10	<b>4.78</b> / 6.05 %	5.52 / 6.33 %	5.25 / 5.44 %	5.88 / 6.28 %	5.20 / 5.63 %
0 – 9	5.49 / 6.14 %	5.96 / 6.41 %	5.90 / 5.89 %	5.58 / 6.03 %	5.67 / 6.03 %
0 – 10	5.15 / 5.51 %	5.54 / 6.15 %	<b>5.02</b> / 6.32 %	5.59 / 5.48 %	5.55 / 5.96 %
0 – 23	5.87 / 6.82 %	6.22 / 7.33 %	5.94 / 6.87 %	5.80 / 7.46 %	6.04 / 7.02 %

Resultatet från Tabell 3 visade att ett neuralt nätverk som tränas upprepade gånger kan visa tydliga variationer i hur bra inläringen gick och att det inte alltid är samma träningsdata som står för det bästa neurala nätverket.

## 5 DISKUSSION

Prognostiseringsmodellen hade en felmarginal vid drift enligt MAPE på 5.67%, se stycke 4.1. Detta går att jämföra med resultaten från Jetcheva, Majidpour och Chen (2014) där deras modell testades på sex olika byggnader och fick en MAPE mellan 2.2 – 8.9%. Då författarna utvärderade MAPE enbart mellan klockan 8 – 20 och under den tiden hade modellen som är framtagen i denna studie en felmarginal på 5.77%. En skillnad mellan modellerna är att i modellen som presenteras i Jetcheva, Majidpour och Chen (2014) sker prognostiseringen enbart en gång per dag och de neurala nätverken är tränade efter det, gentemot modellen som presenteras i denna studie där prognostiseringen kan ske löpande och bör innebära en större felmarginal. Med tanke på att ett bostadshus även är ett välkänt svårt prognostiseringsproblem kan resultatet anses vara godkänt. Lägenhetshusets storlek med närmare 500 studentlägenheter underlättar dock prognostiseringsproblemet gentemot en mindre byggnad eftersom större system rent generellt är enklare att prognostisera. Felmarginalen för modellen bör vara tillräckligt låg för att kunna assistera en smart styrning av ett batteri i en byggnad. Om styrningen exempelvis vill veta hur mycket elektrisk energi som kommer förbrukas de kommande sex timmarna, då kan en del av de för höga prognoserna vissa timmar kompenseras bort av andra som är för låga och ge en träffsäkerhet över denna sex timmars perioden på en bit under 5.67%.

Att det är stora variationer över dagen hur träffsäkert de neurala nätverken prognostiserar kan bero på flera saker. En stor orsak ligger förmodligen i att under vissa timmar är variationerna i lasten större och då är det oundvikligt att få en högre felmarginal eftersom modellen enbart är utformad efter de generella trenderna och inte snabba variationer. Det faktum att en byggnads elektriska last beror till stor del på antal personer som är i byggnaden kan variationer i människors beteende leda till variationer i den elektriska lasten. Att timma tio är den timman som är svårast att prognostisera kan till följd därav bero på att byggnaden som studeras består av studentlägenheter och att det kan vara den timma med högst variationer kring hur många som är hemma. En annan förklaring kan vara att timma tio är en svårare prognostiseringsutmaning än de andra timmarna och att modellens struktur är för enkel vilket leder till underanpassning.

I och med att den data som används är på timbasis kan prognostiseringen ske maximalt en gång per timma. Därmed är det inget problem för funktionen av modellen att proceduren med inläring och testning av de neurala nätverken tar cirka 30 minuter. Dock innebär beräkningsmängden en kostnad som om möjligt bör minimeras. Därför är det viktigt att granska sin modell för att se om delar som ökar beräkningsmängden är motiverade. Resultatet från testning av prognostiseringsmodellen visade att träningsdata användes från allt ifrån enbart den specifika timma som prognostiseras till alla möjliga timmar. Till följd därav skulle modellen prestera sämre om antalet k-värden minskade som testades i k-mean klustringen. Samma test visade även att båda uppsättningarna av inparametrar användes i stor utsträckning och bidrog till en mer träffsäker prognostiseringsmodell. Avseende komplexiteten i strukturen i det neurala nätverket har det inte gjorts några rigorösa tester kring vad som är optimalt, detta har ansetts

vara utanför målet med denna studie. Valen bygger dock på tester som har gjorts i Jetcheva, Majidpour och Chen (2014). Dock är inte de testerna helt tillförlitliga då den studien fokuserar på industrier och kommersiella byggnader och inte bostadshus.

Fortsatt utveckling av prognostiseringsmodellen kan gå i flera riktningar baserat på preferenser. De två vanligaste preferenserna är att försöka öka precisionen i prognoserna eller göra modellen enklare i termer av beräkningsmängd och vid användning. Dilemmat är att enklare modeller i många fall leder till sämre precision och vice versa. Så behöver inte vara fallet, men det är förhållandevis avancerat och tidskrävande att optimera ett neuralt nätverk, vilket kan medföra kostnader som eventuella förbättringar möjligtvis inte kan motivera. Med tanke på prognostiseringsmodellens förhållandevis goda träffsäkerhet i studien och det faktum att de delar av modellen som bidrar till en mer komplicerad modell ser ut att vara motiverade kan det bästa alternativet vara att inte utveckla modellen mer. Detta beror dock helt och hållet på vilka preferenser användaren har.

I Tabell 3 går det att se resultaten från utvärderingen med likadana neurala nätverk som tränas med samma träningsdata och testades. Resultaten visade att inläringen av neurala nätverk kan ha tydliga variationer i resultat och att det inte alltid är ett visst neuralt nätverk som får fram den bästa modellen. Detta motiverar att träna flertalet neurala nätverk parallellt vid varje inläring och sedan välja ut. Ett alternativt sätt hade varit att en gång testa vilket kluster med träningsdata som fungerar bäst och sedan alltid använda det. Med den metodiken hade träningsdatan efter försök alltid bestått av timmarna mellan sex och tio. Det hade inneburit att det sämsta neurala nätverket använts vid försök fyra. Vad som mer talar emot den metodiken är att elektriska lastmönster och vad som korrelerar med den elektriska lasten i byggnader varierar över året.

Vid testning av prognostiseringsmodellen i drift har brist på data ersatts med data ifrån samma timma ett dygn innan. En möjlig förbättringspotential finns i att istället ersätta brist på temperaturdata med prognoser från exempelvis SMHI (Sveriges meteorologiska och hydrologiska institut). Det går även testa att utföra en prognos åt gången och använda det prognostiserade värdet på den elektriska lasten som indata i de efterföljande prognostiseringarna istället för att använda gårdagens värde.

## 6 SLUTSATS

En prognostiseringsmodell för elektrisk lastprognostisering av en byggnad för ett dygn utvecklades i denna studie. Modellen som baserades på neurala nätverk hade i drift en mean average percentage error på 5.67%. Studien visar även på fördelar med att dela upp prognostiseringsproblemet i mindre delar och testa neurala nätverk med olika parametrar innan den bästa väljs. Med denna metodik kunde en enkel struktur upprätthållas samtidigt som träffsäkerhet i prognostiseringen var god. Det visades att korrelationen mellan dessa parametrar och träffsäkerheten för modellen varierade mycket mellan olika tidpunkter under dagen.

I en framtida studie vore det intressant att utveckla en funktion i modellen som detekterar de timmarna där prognostiseringen fungerar sämst och testar olika strukturer i det neurala nätverket för de timmarna för att undvika under- eller överanpassning. Det vore även spännande att studera hur det går att utveckla modellen ytterligare för att fungera ännu bättre i stor skala för många olika typer av byggnader.

## REFERENSER

- Becoming human (2017). *Understanding the structure of neural networks*.  
<https://becominghuman.ai/understanding-the-structure-of-neural-networks-1fa5bd17fef0>  
[2019-05-07]
- Bešli, N. & Dağtekin, Y. (2015). Demand response: A way to balance production and consumption of energy for Turkey. *2015 9th International Conference on Electrical and Electronics Engineering (ELECO)*, ss. 61-65. doi:10.1109/ELECO.2015.7394583
- Borges, C. E., Peña, Y. K. & Fernández, I. (2011). Optimal combined short-term building load forecasting. *2011 IEEE PES Innovative Smart Grid Technologies*, ss. 1-7.  
doi:10.1109/ISGT-Asia.2011.6167091
- Borges, C., Peña, Y., Fernández, I., Prieto, J. & Bretos, O. (2013). Assessing tolerance-based robust short-term load forecasting in buildings. *Energies*, 6(4), ss. 2110-2129.  
doi:<https://doi.org/10.3390/en6042110>
- Celebi, M. E., Kingravi, H. A. & Vela, P. A. (2013). A comparative study of efficient initialization methods for the k-means clustering algorithm. *Expert systems with applications*, 40(1), ss. 200-210. doi:10.1016/j.eswa.2012.07.021.
- Chen, X., Chen, B., Cui, X. & Liu, L. (2015). Research on Smart Grid Load Forecasting Platform Based on Cloud Computing. *2015 International conference on Applied Science and Engineering Innovation*. doi: <https://doi.org/10.2991/asei-15.2015.282>
- Chiang, Y. M., Chang, L. C. & Chang, F. J. (2004). Comparison of static-feedforward and dynamic-feedback neural networks for rainfall-runoff modeling. *Journal of hydrology*, 290(3-4), ss. 297-311. doi:10.1016/j.jhydrol.2003.12.033.
- Covington, P., Adams, J. & Sargin, E. (2016). Deep neural networks for youtube recommendations. *Proceedings of the 10th ACM conference on recommender systems*, ss. 191-198. doi:10.1145/2959100.2959190
- Datanovia (2018) *Determining the optimal number of cluster: 3 must know methods*.  
<https://www.datanovia.com/en/lessons/determining-the-optimal-number-of-clusters-3-must-know-methods/> [2019-05-05]
- Dell, R. M., Moseley, P. T. & Rand, D. A. (2014). *Towards sustainable road transport*. Amsterdam: Academic Press.

- De Myttenaere, A., Golden, B., Le Grand, B. & Rossi, F. (2016). Mean absolute percentage error for regression models. *Neurocomputing*, 192, ss. 38-48.  
doi:<https://doi.org/10.1016/j.neucom.2015.12.114>
- Delreux, T. & Ohler, F. (2019). Climate Policy in European Union Politics. *Oxford research encyclopedia of politics*. doi:[10.1093/acrefore/9780190228637.013.1097](https://doi.org/10.1093/acrefore/9780190228637.013.1097)
- Fahad, M. U. & Arbab, N. (2014). Factor affecting short term load forecasting. *Journal of Clean Energy Technologies*, 2(4), ss. 305-309. doi: [10.7763/JOCET.2014.V2.145](https://doi.org/10.7763/JOCET.2014.V2.145)
- Fernández, I., Borges, C. E. & Peña, Y. K. (2011). Efficient building load forecasting. *ETFA2011*, ss. 1-8. doi:[10.1109/ETFA.2011.6059103](https://doi.org/10.1109/ETFA.2011.6059103)
- Fux, S. F., Benz, M. J., Ashouri, A. & Guzzella, L. (2013). Short-term thermal and electric load forecasting in buildings. *CISBAT*, Lausanne, Schweiz, 4-6 september 2013.  
<https://infoscience.epfl.ch/record/211899/>
- Gerwig, C. (2017). Short term load forecasting for residential buildings - An extensive literature review. *International Conference on Intelligent Decision Technologies*, ss. 181-193.  
doi: [https://doi.org/10.1007/978-3-319-19857-6\\_17](https://doi.org/10.1007/978-3-319-19857-6_17)
- Gnann, T., Stephens, T. S., Lin, Z., Plötz, P., Liu, C. & Brokate, J. (2018). What drives the market for plug-in electric vehicles? -A review of international PEV market diffusion models. *Renewable and Sustainable Energy Reviews*, 93, ss. 158-164. doi:  
<https://doi.org/10.1016/j.rser.2018.03.055>
- Grinblatt, M., Keloharju, M. & Ikäheimo, S. (2008). Social influence and consumption: Evidence from the automobile purchases of neighbors. *The review of Economics and Statistics*, 90(4), ss. 735-753. doi:<https://doi.org/10.1162/rest.90.4.735>
- Hadgu, A. T., Nigam, A. & Diaz-Aviles, E. (2015). Large-scale learning with AdaGrad on Spark. *2015 IEEE International Conference on Big Data*, ss. 2828-2830.  
doi:[10.1109/BigData.2015.7364091](https://doi.org/10.1109/BigData.2015.7364091)
- Hippert, H. S., Pedreira, C. E. & Souza, R. C. (2001). Neural networks for short-term load forecasting: A review and evaluation. *IEEE Transactions on power systems*, 16(1), ss. 44-55.  
doi:[10.1109/59.910780](https://doi.org/10.1109/59.910780)
- Hofmann, T. Schölkopf, B. & Smola, A. J. (2008). Kernel methods in machine learning. *The annals of statistics*, ss. 1171-1220. doi:[10.1214/0090536070000000677](https://doi.org/10.1214/0090536070000000677).
- Jetcheva, J. G., Majidpour, M. & Chen, W. P. (2014). Neural network model ensembles for building-level electricity load forecasts. *Energy and Buildings*, 84, ss. 214-223.  
doi:<https://doi.org/10.1016/j.enbuild.2014.08.004>

- Jones, T. C., Auslander, D. M., Taneja, J., Trager, J., Sankur, M. & Peffer, T. (2012). Improved methods to load prediction in commercial buildings. *ACEEE Summer Study on Energy Efficiency in Buildings*. Kalifornien, USA 12 – 17 augusti 2012.  
<https://aceee.org/files/proceedings/2012/data/papers/0193-000085.pdf>
- Kazmierkowski, M. P., Krishnan, R., Blaabjerg, F. & Irwin, J. D. (2002). *Control in power electronics: selected problems*. Amsterdam; Boston: Academic press.
- Keras (2019). *Initializers*. <https://keras.io/initializers/> [2019-05-10]
- Kuźniar, K. & Zając, M. (2017). Some methods of pre-processing input data for neural networks. *Computer Assisted Methods in Engineering and Science*, 22(2), ss. 141-151.  
<https://comes.ippt.pan.pl/index.php/comes/article/view/33>
- Lin, G. & Shen, W. (2018). Research on convolutional neural network based on improved Relu piecewise activation function. *Procedia computer science*, 131, ss. 977-984.  
 doi:<https://doi.org/10.1016/j.procs.2018.04.239>
- Liu, Y., Wang, W. & Ghadimi, N. (2017). Electricity load forecasting by an improved forecast engine for building level consumers. *Energy*, 139, ss. 18-30.  
 doi:<https://doi.org/10.1016/j.energy.2017.07.150>
- Luo, Z., Small, A., Dugan, L. & Lane, S. (2019). Cloud Chaser: real time deep learning computer vision on low computing power devices. *Eleventh International Conference on Machine Vision*. doi:<https://doi.org/10.1117/12.2523087>
- Machine learning mastery (2019). *How to choose loss functions when training deep learning neural networks*. <https://machinelearningmastery.com/how-to-choose-loss-functions-when-training-deep-learning-neural-networks/> [2019-05-08]
- McLoughlin, F. & Conlon, M. (2015). Secondary re-use of batteries from electric vehicles for Building Integrated Photo-Voltaic (BIPV) applications, *PV CROPS Technical Report*.  
<https://arrow.dit.ie/cgi/viewcontent.cgi?article=1001&context=dubenrep>
- Mohamad, I. B. & Usman, D. (2013). Standardization and its effects on K-means clustering algorithm. *Research Journal of Applied Sciences, Engineering and Technology*, 6(17), ss. 3299-3303.  
<https://pdfs.semanticscholar.org/1d35/2dd5f030589ecfe8910ab1cc0dd320bf600d.pdf>
- Notton, G., Stoyanov, L., Ezzat, M., Lararov, V., Diaf, S. & Cristofari, C. (2011). Integration limit of renewable energy systems in small electrical grid. *Energy Procedia*, 6, ss. 651-665.  
 doi:10.1016/j.egypro.2011.05.075

- Nyce, C. & Cpcu, A. (2007). Predictive analytics white paper. *American Institute for CPCU. Insurance Institute of America*, 9-10. <http://www.the-digital-insurer.com/wp-content/uploads/2013/12/78-Predictive-Modeling-White-Paper.pdf>
- Omidvar, O. & Dayhoff, J. (1997). *Neural networks and pattern recognition*. San Diego: Academic Press.
- Radiuk, P. M. (2017). Impact of training set batch size on the performance of convolutional neural networks for diverse datasets. *Information Technology and Management Science*, 20(1), ss. 20-24. doi: 10.1515/itms-2017-0003
- Rahman, S. M. & Vega, R. (2015). Machine Learning Approach Applied in Electricity Load Forecasting: Within Residential Houses Context. *ASHRAE Transactions*, 121, ss 1-8. [https://search.proquest.com/docview/1725466099?accountid=9670&rfr\\_id=info%3Axri%2Fsid%3Aprimo](https://search.proquest.com/docview/1725466099?accountid=9670&rfr_id=info%3Axri%2Fsid%3Aprimo)
- Ramchoun, H., Idrissi, M. A. J., Ghanou, Y. & Ettaouil, M. (2016). Multilayer Perceptron: Architecture Optimization and Training. *IJIMAI*, 4(1), ss. 26-30. doi:10.9781/ijimai.2016.416
- Raza, M. Q. & Khosravi, A. (2015). A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings. *Renewable and Sustainable Energy Reviews*, 50, ss. 1352-1372. doi:<https://doi.org/10.1016/j.rser.2015.04.065>
- Sandels, C., Brodén, D., Widén, J., Nordström, L. & Andersson, E. (2016). Modeling office building consumer load with a combined physical and behavioral approach: Simulation and validation. *Applied energy*, 162, ss. 472-485. doi:10.1016/j.apenergy.2015.10.141
- Thokala, N. K., Bapna, A. & Chandra, M. G. (2018). A deployable electrical load forecasting solution for commercial buildings. *IEEE International Conference on Industrial Technology*, ss. 1101-1106, Lyon, France, 20-22 februari 2018. doi:10.1109/ICIT.2018.8352332
- Towards Data Science (2019). *Support Vector Machine – Simply explained*. <https://towardsdatascience.com/support-vector-machine-simply-explained-fee28eba5496> [2019-05-09]
- Wang, F., Wang, K. & Jiang, F. (2013). An Improved Fusion Method of Fuzzy Logic Based on k-mean Clustering in WSN. *Sensors & Transducers*, 157(10), ss. 20. <http://search.proquest.com/docview/1510298089/>.
- Zhao, H. X. & Magoulès, F. (2012). A review on the prediction of building energy consumption. *Renewable and Sustainable Energy Reviews*, 16(6), ss. 3586-3592. doi:<https://doi.org/10.1016/j.rser.2012.02.049>



# HÖGSKOLAN I BORÅS

Besöksadress: Allégatan 1 · Postadress: 501 90 Borås · Tfn: 033-435 40 00 · E-post: [registrator@hb.se](mailto:registrator@hb.se) · Webb: [www.hb.se](http://www.hb.se)