

Lara Hammer

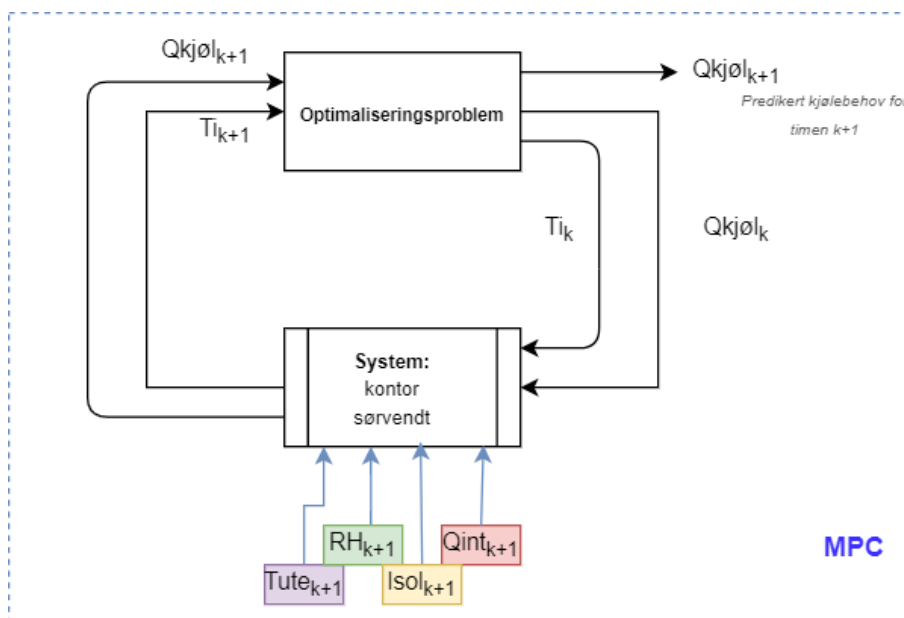
Prognoseregulering av kjølesystemer for norske kontorbygg

Predictive control of the space-cooling system for Norwegian office buildings

Masteroppgave i Energi og miljø

Veileder: Laurent Georges

Februar 2020



Lara Hammer

Prognoseregulering av kjølesystemer for norske kontorbygg

Predictive control of the space-cooling system for
Norwegian office buildings

Masteroppgave i Energi og miljø
Veileder: Laurent Georges
Februar 2020

Norges teknisk-naturvitenskapelige universitet
Fakultet for informasjonsteknologi og elektroteknikk
Institutt for energi- og prosessteknikk



Kunnskap for en bedre verden

MASTER THESIS

for

Lara Hammer

Autumn 2019

*Predictive control of the space-cooling system for Norwegian office buildings**Prognoseregulering av kjølesystemer for norske kontorbygg***Background and objective**

The building sector consumes about 40% of the Norwegian energy use. During the latest years, the need for mechanical cooling in Norwegian office and commercial buildings has increased. For office buildings, it is not unusual that the installed power that is higher for cooling than for heating. One way to reduce space-cooling energy and power is to optimize the control. In that respect, predictive control operates the building taking the near-future predictions of the operating conditions into account (such as the weather forecast, day-ahead electricity prices and expected user behaviour). By storing thermal energy in the building thermal mass or storage tanks, predictive control has the potential to reduce the cooling energy needs and power.

In spring 2019, the specialization project focused on so-called rule-based control. This master thesis is a direct continuation by extending this work to model predictive control (MPC) applied to space-cooling. When designing a MPC, identifying an accurate but simple control model is acknowledged as most time-consuming and critical part. Therefore, an important part of the Master work is to investigate different data-driven modelling strategies to establish the control model of the MPC. The research will be simulation-based using the case of a typical office building in IDA ICE.

The following tasks are to be considered:

1. Literature review of the most common space-cooling systems, the current control strategies applied to office buildings and MPC (with a special focus on cooling).
2. Use a detailed IDA ICE model of a typical office building in order to generate data to calibrate the control model (both black and grey-box modelling will be considered).
3. Calibrate the control model on a part of the virtual measurement data and validate the model on the rest of the dataset.
4. If enough time, when the control model is established, develop a MPC based on this model and compare its performance to a standard control for this same office building.

-- ” --

Within 14 days of receiving the written text on the master thesis, the candidate shall submit a research plan for his project to the department.

When the thesis is evaluated, emphasis is put on processing of the results, and that they are presented in tabular and/or graphic form in a clear manner, and that they are analyzed carefully.

The thesis should be formulated as a research report with summary both in English and Norwegian, conclusion, literature references, table of contents etc. During the preparation of the text, the candidate should make an effort to produce a well-structured and easily readable report. In order to ease the evaluation of the thesis, it is important that the cross-references are correct. In the making of the report, strong emphasis should be placed on both a thorough discussion of the results and an orderly presentation.

The candidate is requested to initiate and keep close contact with his/her academic supervisor(s) throughout the working period. The candidate must follow the rules and regulations of NTNU as well as passive directions given by the Department of Energy and Process Engineering.

Risk assessment of the candidate's work shall be carried out according to the department's procedures. The risk assessment must be documented and included as part of the final report. Events related to the candidate's work adversely affecting the health, safety or security, must be documented and included as part of the final report. If the documentation on risk assessment represents a large number of pages, the full version is to be submitted electronically to the supervisor and an excerpt is included in the report.

Pursuant to “Regulations concerning the supplementary provisions to the technology study program/Master of Science” at NTNU §20, the Department reserves the permission to utilize all the results and data for teaching and research purposes as well as in future publications.

The final report is to be submitted digitally in DAIM. An executive summary of the thesis including title, student's name, supervisor's name, year, department name, and NTNU's logo and name, shall be submitted to the department as a separate pdf file. Based on an agreement with the supervisor, the final report and other material and documents may be given to the supervisor in digital format.

- Work to be done in lab (Water power lab, Fluids engineering lab, Thermal engineering lab)
 Field work

Department of Energy and Process Engineering, August 2019

Laurent Georges, Associate Professor
Academic Supervisor

Research Advisor:
Rasmus Høseggen, Evotek AS, rh@evotek.no

Forord

Masteroppgaven utgjør 30 studiepoeng for femårig-masterprogram innenfor Energi og miljø med studieretning Energiplanlegging og miljøanalyse med hovedretning Energiforsyning og klimatisering av bygninger.

Dette semesteret har bestått av mye prøving og feiling. Fagområder utenfor min retning har blitt utforsket, slik som ulike nevrale nettverk innenfor maskinlæring. I den anledning har det vært godt å ha faglig støtte både hos Evotek AS og av Laurent Georges på NTNU.

Særlig har det vært godt å ha min medveileder Rasmus Z. Høseggen med gode tekniske og faglige råd. For forståelse av nevrale nettverk takker jeg doktorgradsstudenten Sven Opalic hos Evotek AS, som både har vært åpen for diskusjon og anbefalt ulike online kurs i maskinlæring. Videre setter jeg pris på den støtte min veilder Laurent Georges har gitt, både når det gjelder i person og faglig.

Sist men ikke minst vil jeg takke kjæresten min, Christopher, som har holdt ut med meg i perioder der masteren har vært ekstra krevende.

Så håper jeg oppaven faller i smak.

Med vennlig hilsen

Lara Hammer

Oslo, 5. februar 2020

Sammendrag

Denne oppgaven omtaler ulike modelleringsstrategier for prediksjon av kjølebehov for bruk av prognose modellregulering(MPC) av kjølesystemer i kontorbygg. Ved å predikere kjølebehovet er det mulig å optimalisere reguleringen av kjølesystemer og redusere bruken av energi til kjøling. Energibruk til kjøling i norske kontorbygg har økt de siste ti årene . Samtidig er presset fra offentlige myndigheter om redusert energibruk i byggesektoren aldri har vært større.

Prediksjon av kjølebehov gir muligheter til å produsere energi til kjøling på et tidspunktet før kjølebehovet inntreffer. Samtidig muliggjør det utnyttelse av mer optimale kjølesystemer og nøyaktig regulering. For MPC av kjølesystemer er det mulig bruke vær-, kjølefaktor-, energipris- og internlastprognose og forutse utviklingen til kjølebehovet frem i tid. Kjølebehovet avhenger i stor grad av værforholdene. Derfor er det motiverende at værprognoser fra metrologiske institutt har aldri vært bedre. Samtidig er energiprisprognose lett tilgjengelig fra Nord Pool som gir indikasjoner på når det er økonomisk gunstig å produsere energi til kjøling. Kombinasjonen av kjølemaskin og lager kan være et fornuftig kjølesystem for prognose modellregulering. Dette fordi lageret kan fungere som buffer i perioder der det er gunstig å produsere mens behovet er lavt. I tillegg ved bruk av MPC er det mulig å oppnå lavere reguleringstap og mer nøyaktig regulering. I MPC oppdateres prognosen i faste intervaller, eksempelvis hver time, for å korrigere for eventuelle feil.

For optimal MPC er det avgjørende å ha treffsikre systemmodeller for prediksjon. I den anledning har fire modeller blitt analysert med hensyn på treffsikkerhet, “Normalized root mean square error” NRMSE. De fire modellene er basert på bygningskroppen til ett standardisert kontorbygg. Disse er alle modellert for å predikere kjølebehovet til bygget. Det har blitt programmert en grå-boks modell i form av ett termisk nettverk. Grå-boks modellene benytter seg av fysiske prinsipper og målt bygningsdata. Videre har det blitt utviklet tre nevralt nettverk innenfor svart-boks metoden. Disse benytter seg av maskinlæringsteknikk og er avhengige av input- og outputen til det som modelleres og trenes basert på store mengder måledata fra bygget. Felles for de nevralt nettverkene viste seg å være høy treffsikkerhet for lengre treningsperioder, jo større mengde data dess bedre prediksjon av kjølebehov. Det termiske nettverket viste det motsatte. Samtidig kom det frem at de flerlagsforovernettverket(FN) fikk høyest NRMSE.

I analyse av prediksjonen til FN ble forenklet MPC av kjølebehov utviklet med betingelser for maksimal effektkapasitet og minimal innetemperatur for kjølebehov. Det interessante ved prediksjonene til FN nettverket var at en typisk “gjennomsnittlig dag” i vår- og sommermånedene ga høyere NRMSE enn dag med maksimalt kjølebehov og solstråling. Avvikende tilstand ga lavere treffsikkerhet. Uavhengig av dette ser det like vel ut til at FN modellen har høyest presisjon i sin prediksjon av kjølebehov, med hele NRMSE på ca 95 prosent. Dette gjør at med de forutsetningene som er tatt i analysen konkluderes det med at kjølebehovet til ett standardisert kontorbygg kan predikeres med høy treffsikkerhet. Dette gjør kjølesystemer regulert med MPC kan ha mulighet til å utnytte presise prediksjoner og forutse utviklingen til byggets kjølebehov frem i tid.

Summary

This thesis investigates different modelling strategies to predict cooling need for usage in model predictive control(MPC) of cooling systems in office buildings. Cooling need prediction enable optimization of the control of cooling systems and thereby reduce the energy usage related to cooling. During the last decade the usage of cooling energy has increased in Norwegian office buildings. Meanwhile the pressure on reduced energy consumption in the building sector from the Norwegian government has never been higher.

Prediction of cooling need gives opportunities to produce cooling energy before the time cooling need occurs. In addition, the prediction gives opportunity to exploit more optimized cooling systems and more accurate control. With model predictive control of cooling systems it is possible to use predictions of weather, coefficient of performance, energy price and internal gains and foresee the development of cooling need for the next hours or days. Coefficient of performance depends on the outdoor temperature and the load factor of the cooling machine. Thus it might be predicted based on these factors. The forecast of the energy price is available at Nord Pool and gives indications of when it is economically beneficial to produce cooling energy. Cooling systems with cooling machine and thermal storage might be suitable for model predictive control. This due to possibility of using energy from storage meanwhile it is not economically beneficial to produce. Furthermore with predictive model control the prediction is updated with fixed intervals, example each hour or 15 minutes, to correct errors.

For effective model predictive control it is crucial with accurate predictive system models. In relation to this, four different models based on the building envelope and balance of a standardized office building has been developed to predict cooling need. One of them was a grey-box model, thermal network. These models use the physical features of the building and measured data. Furthermore it has been developed three neural networks within the black-box method. These exploits machine learning and depend solely on measured data as input and output in the training process. In the analysis all three neural networks seem to have higher NRMSE for longer training periods, the more data the models was trained on, the more accurate predictions they produced. In terms of the thermal network model the network had the opposite response, it had higher NRMSE for lower amount of input data. In the end the feedforward neural network(FN) seemed to have the most accurate predictions. Moreover the predictions of the FN seemed to respond differently depending on weather. For a average day the accuracy seemed to be higher compared to a day with high solar radiation and a day when the cooling need was at its maximum. In colclusion, with the assumptions and considerations taken in this thesis it is possible to predict cooling need for uage in MPC with high accuracy. This makes it possible to forsee the cooling need for a office building many hours ahead.

Innhold

Forord	3
Sammendrag	i
Summary	i
Innholdsfortegnelse	v
Forkortelser	vi
Definisjoner	1
1 Introduksjon	1
1.1 Bakgrunn	1
1.1.1 Prognose som tiltak for optimal regulering av kjølesystemer	2
1.2 Mål og begrensninger	2
1.2.1 Mål	2
1.2.2 Begrensninger	3
1.3 Oppgavens oppbygning	3
2 Kjølesystemer	4
2.1 Kjølebehov	4
2.2 Kjølemaskiner	4
2.2.1 Kjølefaktor	5

2.3	To metoder for tilførsel av kjøling	6
2.4	Lagring av energi til kjøling	6
2.4.1	Bruk av energilager	7
3	Generelt om Styring og regulering	8
3.1	Forskjellen mellom styring og regulering	8
3.1.1	Kaskaderegulering	9
3.1.2	Regulering med kompensering	9
3.2	Vanlige regulering- og styringsteknikker for kjøling	10
3.3	Regulatorer	11
4	Prognosestyring og -regulering	12
4.1	Prognosemodellregulering	12
4.1.1	Hovedgrupper innenfor modellering	12
4.1.2	Prognose- og reguleringshorisont	16
4.1.3	Studier med prognosemodellregulering av kjølesystemer	17
4.1.4	CASE - REMA 1000 Vagle	18
4.2	Prognose regelbasertstyring	18
4.3	Generelt om værprognoser og strømprisprognose	19
4.3.1	Værprognosedata fra Meterologiske institutt	19
4.3.2	Prognose av strømpris	22
5	Metode	24
5.1	Hypotese	24
5.2	Modell for standardisert kontorbygg i IDA ICE	24
5.2.1	Bygningssimulerings programvare	25
5.2.2	Termiske soner	25
5.2.3	Bygningskroppen	26
5.2.4	Interne varmetilskudd	26
5.2.5	Inneklima - Kjølesettpunkt	26
5.2.6	Ideelle kjølere for kjølebehov	27

5.2.7	Klimafilere til IDA ICE	27
5.3	Utviklet prognosemodellregulering for kjølebehov	27
5.3.1	Programmeringsspråk for utvikling av modeller og MPC	29
5.3.2	Optimeringsalgoritme til MPC utviklet til flerlagsforover nettverk	29
5.3.3	Egenskapene til modellene	30
5.3.4	Praktisk implementering av MPC	31
6	Resultater	33
6.1	Valgt sone	33
6.2	Sammenligning av grå-boks og svart-boks modeller	33
6.2.1	Treffsikkerheten til FN og NX over lengre treningsperioder	35
6.3	MPC kjølebehov	36
6.3.1	Dag med maksimal solinnstråling	36
6.3.2	Gjennomsnittlig dag og dag med maksimalt kjølebehov over prognosehorisonten	37
7	Diskusjon	40
8	Konklusjon	44
9	Videre arbeid	45
	Referanser	46
	Appendiks	51
9.1	Plantegninger	51
9.2	Fasadetegninger	52
9.3	Matlab koder	53
9.3.1	Tilbakevendende nettverk - NX	53
9.3.2	Flerlagsforover nettverk - FN	54
9.3.3	Lag-tilbakevendende nettverk - LRN	56
9.3.4	Termisk nettverk	57
9.3.5	Termisk nettverk modellen til sonen	57

9.3.6 Forenklet MPC til FN- Optimering	58
--	----

Forkortelser

MPC = prognosemodellregulering

PRBC = prognose regelbasertstyring

FN = Flerlagsforovernett nettverk

NX = Tilbakevendende nettverk

TN = Termisk nettverk

MSE = Mean square error

NMSE = Normalized square error

MAE = Mean absolute error

RMSE = Root mean squared error

NRMSE = Normalized Root Mean Squared Error

NVE = Norges vassdrags- og energidirektorat

Definisjoner

Kjølebehov = Behovet for fjernet overskuddsvarme i sone, der overskuddsvarmen er gitt av differansen mellom varmeoverskuddet i sonen og varmetapet i sonen. Overskuddsvarmen er således definert av differansen mellom innetemperatur og kjølesettpunkt (Standard-Norge (2016)).

Kjølefaktor = Virkningsgrad som sier hvor mye energi til kjøling som blir produsert relativt til hvor mye elektrisk energi som brukes til å produsere (Joe and Karava (2019))).

Diffus solstråling = Sollys som er gjennom skyer og er spredt av molekyler i atmosfæren (Thue (2016)).

Direkte solstråling = Kortbølget og direkte stråling fra solen uten forstyrrelser fra partikler eller molekyler i atmosfæren (Thue (2016)).

Global solstråling = Diffus og direkte kortbølget stråling utgjør den globale solstrålingen fra solen (Thue (2016)).

Styring = Bevisst påvirkning av et system ved bruk av åpen sløyfe (Jonsson (2014)).

Regulering = Bevisst påvirkning av et system ved bruk av en lukket reguleringsløyfe (Jonsson (2014)).


Regulator = Komponenten som beregner nødvendige påvirkningen av systemet for å oppnå en ønsket tilstand (Sharma (2017)).

Introduksjon

1.1 Bakgrunn

I løpet av det siste tiåret har fokuset på energieffektivitet, bærekraft og redusert klimagassutslipp vokst. Norge er en av flere land som har satt seg mål om reduksjon i energibruk og klimagassutslipp. Ett av klimamålene til Norge er opp mot den europeiske unionen(EU). Dette klimamålet krever 40 prosent reduksjon i klimagassutslipp innen 2030 sammenlignet med 1990. Etter forslag fra den norske regjeringen, mars 2019, ønskes det at dette målet skal økes ytterligere til 55 prosent. For å oppnå slike reduksjoner i klimagassutslipp er avgjørende at Norges energibruk reduseres (Miljødepartementet (2019)).

Av Norges totale energibruk i 2018 utgjorde bygningssektoren hele 37 prosent, mens transportsektoren utgjorde energibruken bare 28 prosent, se figur 1.1 (Spilde et al. (2018)). Bygningssektoren er en av sektorene som utgjør mest av Norges energibruk. For reduksjon av energibruk i bygningssektoren er blant annet adferdsbevisstgjøring av bruker, arealeffektivisering, effektivisering av regulering av tekniske installasjoner, optimalisere byggets energisystem og komponenter, utbedring av bygningskroppens termiske egenskaper og bruk av fornybar energiproduksjon avgjørende (Spilde et al. (2018)). Basert på Norges vassdrags- og energidirektorat(NVE) skal energibruken til bygningssektoren reduseres med hele fire TWh per år fra 2016 til 2035, se figur 1.1.



Figur 1.1: Framskrivning energibruk 2020-2035, historisk energibruk 2010-2016 (Spilde et al. (2018)).

Samtidig sammenlignet med tidligere, stiller byggherre og leietaker til kontorer strengere krav i dag til god termisk komfort. Dette krever høyere energibruk i kontorer til blant annet kjøling (THEMA Consulting Group (2013)). Kontorbygg har ofte store interne laster og mer kjølebehov enn andre bygningskategorier, eksempelvis større enn undervisningsbygg, hotell og kulturbygg (Langseth (2016)).

1.1.1 Prognose som tiltak for optimal regulering av kjølesystemer

I løpet av denne oppgaven legges det fokus på et av tiltakene for redusert energibruk. Dette er optimalisering av reguleringen til kjølesystemene i norske kontorbygg. Dette i form av prognoseregulering/-styring. Det er to former for prognoseregulering/-styring. Den ene er prognosemodellregulering(MPC), den andre er prognose regelbasertstyring(PRBC). Førstnevnte benytter seg av modelleringsteknikker for å optimalt regulere kjølesystemet. Sistnevnte bruker beslutningsregler for å optimalisere reguleringen. Felles for de to formene er at de har eksterne prognoser som input, eksempelvis værprognoser. Førstnevnte vektlegges, fordi modelleringen av prognosemodellene med eksterne prognoser som input kan gi muligheter for å si noe om utviklingen til en tilstand i bygget, eksempelvis utviklingen til kjølebehovet. PRBC gir ikke de samme mulighetene ettersom bygget og systemene ikke modelleres.

Værprognoser fra metrologiske institutt har aldri hatt høyere treffsikkerhet, samtidig som nye modelleringsteknikker for utvikling av prognosemodeller har kommet på markedet (Homleid et al. (2016)). Muligheten for å regulere et kjølesystem, basert på en prognose av hvordan kjølebehovet vil utvikle seg, gir muligheter for energibesparelser, både på grunn av reduksjon i reguleringstap og optimalisering av bruk av tekniske installasjoner. Tidligere har modelleringsteknikker vært basert på empiri og teoretiske sammenhenger blitt benyttet. I dag kan modelleringsteknikker innen maskinlæring benyttes. Modellene kan blant annet lære basert på den historisk måledata til bygget og værhistorikk. I utviklingen av MPC kan disse nye modelleringsteknikkene sikre høyere treffsikkerhet.

1.2 Mål og begrensninger

1.2.1 Mål

Hovedmålet til oppgaven er å undersøke ulike modelleringsstrategier for prediksjon av kjølebehov for bruk av prognosemodellregulering av kjølesystemer i kontorbygg. Hensikten med dette er å optimalisere reguleringen av kjølesystemer i kontorbygg.

Underliggende mål:

- Introdusere tekniske installasjoner i kjølesystemer.
- Undersøke vanlige reguleringsteknikker og forskjellige regulatorer.
- Gjøre litteraturstudie av prognosemodellregulering.

- Utvikle ulike prognosemodeller for kontorcelle og predikere kjølebehov og innetemperatur. Disse modellene skal kunne benyttes i en prognosemodellreguleringsløyfe.
- Sammenligne treffsikkerheten til de ulike prognosemodellene.
- Utvikle forslag til prognosemodellregulering(MPC) av kjølebehov.
- Diskutere hvilke gevinster bruk av prognosemodellregulering kan gi.

1.2.2 Begrensninger

I metode- og resultatdelen er prognose av kjølebehov vektlagt. Modellering av tekniske installasjoner og komponenter i kjølesystem har ikke blitt lagt fokus på. Det er foreslått å se på for videre arbeid.

Etter oppgavens definisjon har modellering av prognosemodell for MPC blitt vektlagt. Dette gjør at MPC-en ikke har blitt testet i bygningsmiljø. En av årsakene til dette er begrensningen i samkjøring mellom Matlab og IDA ICE. Imidlertid har modellenes treffsikkerhet blitt evaluert og analysert opp mot ideell IDA ICE modell.

Modelleringen av bygningskroppen for prediksjon av kjølebehov og innetemperatur har blitt begrenset til mest utsatte kontorcelle, sørvendt kontorcelle.

1.3 Oppgavens oppbygning

1. Første kapittel er introduksjon.
2. Andre kapittel er litteraturstudie om kjølesystem.
3. Tredje kapittel er litteraturstudie om styring og regulering.
4. Fjerde kapittel er litteraturstudie om prognosestyring og -regulering og teori relatert til statistisk avvik.
5. Femte kapittel er metodedel med beskrivelse av kontormodell og prognosemodeller.
6. Sjette kapittel er resultatene relatert til prognosemodellene og MPC.

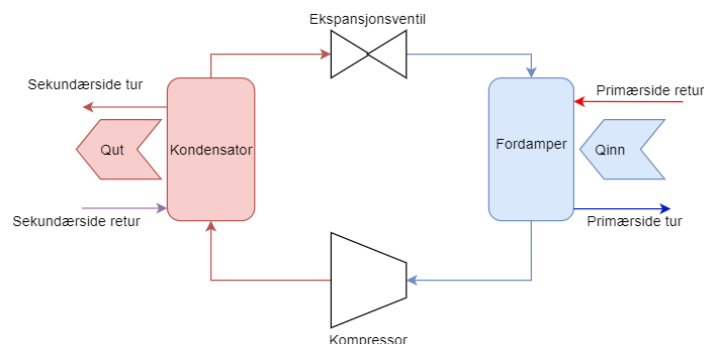
Kjølesystemer

2.1 Kjølebehov

Kjølebehovet til en bygning avhenger av flere faktorer. Basert på ulike studier har kjølebehovet stor sammenheng med interne laster og værforhold (Causone et al. (2010), Wang et al. (2018), Wittchen et al. (2005)). De interne lastene kan være personbelastning, teknisk utstyr og belysning. Disse lastene emitterer varme til sonen. Værforhold påvirker også varmebalansen til bygningskroppen. Blant de værparametrene som har størst påvirkning på kjølebehovet er solinnstråling og utetemperatur. I særlig kontorbygg som ofte har stor andel vinduer vil strålingsvarme inn til sone være større. Mens utetemperatur kan gi både varmetap og varmeoverskudd avhengig av temperaturdifferansen mellom ute og inne (Wang et al. (2018)).

2.2 Kjølemaskiner

Kjølemaskiner fungerer som en reversert varmepumpe. Dette betyr at kjølemediet tar opp varme ved bruk av en fordamp(er)(kald side), og avgir varme ved bruk av en kondensator(varm side), se figur 2.1. Vanligste formen for kjølesyklus er damp-kompresjon-kjølesyklus. Et sirkulerende kjølemedium sørger for varmeoverføringen ved faseendring fra væske til damp. Kompressor og ekspansjonsventil sørger for å endre trykket til kjølemediet.



Figur 2.1: Damp-kompresjon-kjølesyklus (Catano et al. (2013)).

Isvannsmaskiner er en ofte brukt kjølemaskin. Den avgir kjøling direkte til et isvannsystem. Vann blir kjølt ned i en fordampere og sirkulerer til kjølebatterier og lokale kjøleenheter. De lokale kjøleenhetene kan for eksempel være kjøletak eller fancoils. En tørrkjøler brukes for å avkjøle kondensatoren, der varmen fra kjølemaskinen avgis. Denne står ute på taket. Når utetemperaturen er lav nok kan tørrkjøleren brukes til frikjøling. Da vil det vannbårne isvannsystemet gå utenom isvannmaskinen og direkte til tørrkjøleren. Isvannmaskinen slås av, her kompressoren, og sirkulasjonspumper og vifter i tørrkjøleren går (Dokka (2013)).

Direkteekspansjonssystemer er ett annet eksempel på kjølemaskin. Det er direkte varmeveksling mellom luft eller vann og kuldemedium. Slike systemer kan brukes for kjølebatterier ved at fordampere sitter i luftstrømmen (Dokka (2013)).

2.2.1 Kjølefaktor

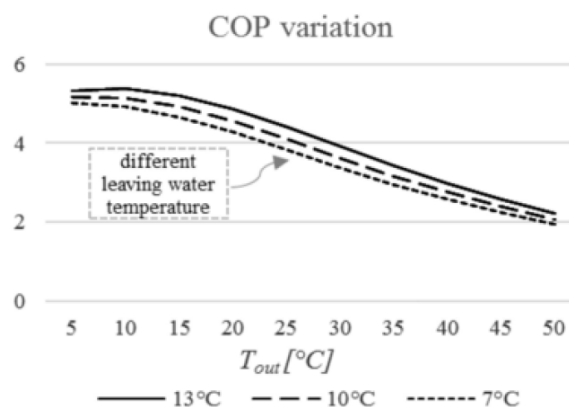
Kjølefactoren til en kjølemaskin er definert som:

$$COP_{kjøling} = \frac{Q_f}{W} \quad (2.1)$$

Q_f er produsert kjøling og W er elektrisk energi brukt for å produsere kjøleenergien. Enhetene deres er enten effekt(W) eller energi(Wh). Kjølefactoren er en virkningsgrad som sier hvor mye energi som blir produsert i forhold til hvor mye energi som brukes for å produsere (Arya and Chavda (2014)).

Kjølefaktor relativt utetemperatur

Kjølefaktor varierer med utetemperaturen når overskuddsvarmen dumpes mot uteluften. I figur 2.2 øker kjølefactoren for lavere utetemperaturer. Dette kan forklares med at temperaturdifferansen mellom kondenseringstemperaturen og utetemperaturen øker og kjølemediet må komprimeres til et høyere trykk for å kondensere. Dette krever elektrisk arbeid. Samtidig varierer kjølefactoren med ulike turtemperaturer fra kjølemaskinen. Høyere turtemperaturer gir høyere kjølefaktor (Joe and Karava (2019)).



Figur 2.2: Kjøleytelse relativt til utetemperatur(Joe and Karava (2019)).

2.3 To metoder for tilførsel av kjøling

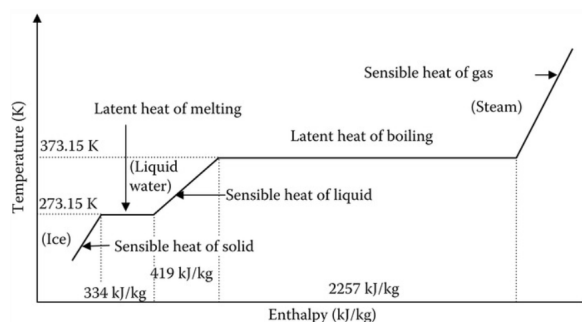
Det er to ulike metoder for tilførsel av kjøling:

- **Ventilasjonskjøling:** kjøler ventilasjonslufta, oftest ved hjelp av kjølebatterier. Her kan både isvannmaskin(vannbåren) og DX-system(fordamper i tilluftskanalen) brukes.
- **Romkjøling:** tilfører kjøling i hver enkelt sone av bygget. For romkjøling brukes oftest kjølebafler, kjøletak eller fancoils. Disse bruker blant annet isvann fra kjøleanlegget (Byggforskserien (2010)).

2.4 Lagring av energi til kjøling

Lagring av termisk energi inndeles i tre hovedgrupper; følbar, latent og termo-kjemisk energilagring. Termokjemisk lagring har ikke blitt utviklet kommersielt og vil dermed ikke omtales mer i denne oppgaven. Følbar- og latent energilagring er kommersialisert. Følbar varme endrer temperaturen til det termiske mediet som muliggjør lagring av energi. Dette kan eksempelvis være ved bruk av vann i en vanntank. For latent varme forekommer en faseendring av det termiske mediet. Latent energilagring krever mindre lagringsvolum og gir mindre temperaturvariasjoner. Varmekapasiteten er høyere enn følbarlagring på grunn av faseendringen av mediet, eksempelvis fast- til væskeform eller væske- til gassform. Temperaturen til det termiske mediet holdes tilnærmet konstant ved faseendring, noe som gjør prosessen mer stabil. Tre typiske lagringsformene ved latent varme er isvanns-, saltvanns- og polymerlagring (Sarbu and Sebarchievici (2018)).

I figur 2.3 illustreres latent og følbar varmeoverføring for rent vann. Grafisk vises latent varmeoverføring med konstant temperatur og lange plataer med økning i varmeinnholdet til mediet(entalpi). I tillegg vises det at plataene forekommer i faseovergangene, smelting av is og oppvarming av vann. Samtidig vises følbar varmeoverføring med stigende temperaturkurver og noe lavere økning i varmeinnhold sammenlignet med latent varme (Sun (2011)).

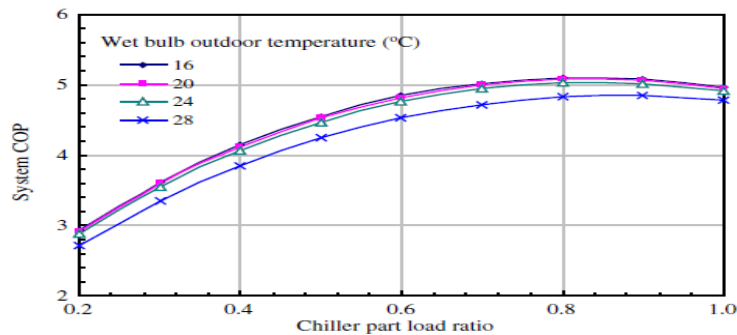


Figur 2.3: Kjøleytelse relativt til utetemperatur(Sun (2011)).

2.4.1 Bruk av energilager

Hensikten med lagring av energi til kjøling er at energien kan lagres for å brukes på et senere tidspunkt. Lageret kan fungere som en buffer for å møte kjølebehovet.

Kjølemaskiner dimensjoneres ofte til å dekke maksimalt kjøleeffektbehov. I løpet av året er det sjeldent maksimalt effektbehov oppstår samtidig som få kjølesystemer bruker lager som buffer. Derfor er det en del kjølemaskiner som har dellastdrift eller intermittert drift som reduserer ytelsen til aggregatet og ofte gir unødvendig slitasje av kompressorer. En måte å løse dellastproblematikken er å bruke ett termisk lager slik at kjølemaskinen kan driftes mer kontinuerlig med maksimal kapasitet oftere. Dette vil øke ytelsen til aggregatet betraktelig. Sammenhengen mellom dellast og kjølefaktor er illustrert i figur 2.4. Grafisk vises økt ytelse som en konsekvens av økt last (Yu and Chan (2008)).




Figur 2.4: Kjøleytelse relativt til lastfaktor(Yu and Chan (2008)).

Generelt om Styring og regulering

3.1 Forskjellen mellom styring og regulering

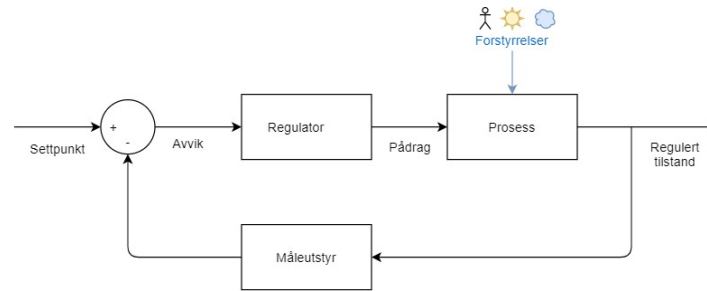
Styring er en bevisst påvirkning av et system ved bruk av åpen sløyfe. Styringen av systemet vil påvirkes av målinger utenom den styrte tilstanden, eksempelvis utetemperaturkompensering, modellstyring og manuell styring. Utetemperaturkompensering styrer systemets tilstand basert på utetemperatur, eksempelvis settpunkt for innetemperatur eller tilluftstemperatur. For manuelt styrte systemer utfører menneske den direkte påvirkningen av systemet (Jonsson (2014)).

En åpen sløyfe har ingen tilbakekobling. Dette betyr at tilstanden y styres ene og alene av inngangsstørrelsen x , se figur 3.1.



Figur 3.1: Blokkdiagram for åpen styringsløyfe (Trond Andresen (2016), illustrert L. Hammer).

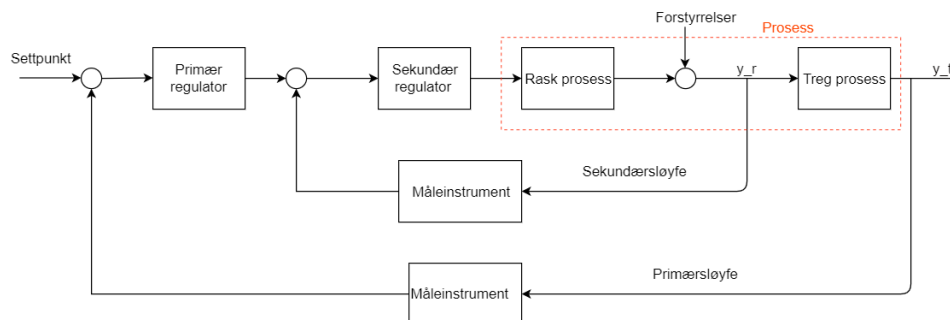
Regulering er en bevisst påvirkning av et system ved bruk av en lukket reguleringsløyfe (Jonsson (2014)). Påvirkningen bestemmes av avviket mellom målt og ønsket tilstand, eksempelvis settpunkt og målt innetemperatur. Lukket reguleringsløyfe med slik påvirkning kalles tilbakekoblingsløyfe. I figur 3.2 illustreres ett forenklet blokkdiagram med lukket reguleringsløyfe. Settpunkt gir ønsket verdi for regulert tilstand, denne blir omgjort til en referanseverdi (Trond Andresen (2016)).



Figur 3.2: Blokkdiagram for lukket reguleringsløyfe (Trond Andresen (2016), illustrert L. Hammer).

3.1.1 Kaskaderegulering

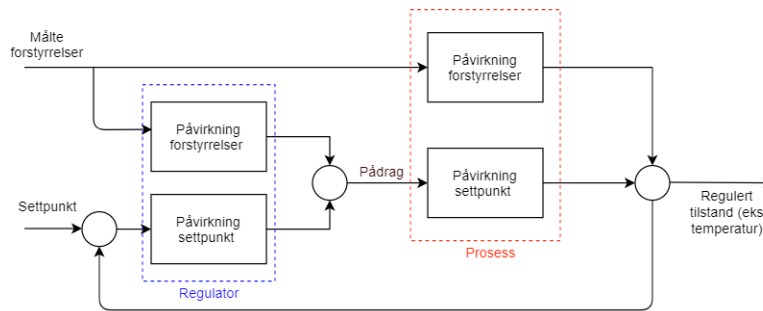
Kaskaderegulering benyttes hovedsakelig for systemer med ulineære pådrag, tidsforsinkelser eller tregheter . I et kjøleanlegg er det gjerne en eller flere komponenter som har store tregheter. Eksempelvis for vannbårne systemer er rørstrekket frem til kjølebatteri en tidsforsinkelse. I figur 3.3 vises en sekundærløyfe (intern tilbakekopling) med treg prosess og primærløyfe (ytre tilbakekopling) med rask prosess. Sekundærløyfen tar imot referanseverdi fra primærløyfe. Slik vil rask prosess regulere i henhold til behovet til den treg prosessen. Fordelen med denne formen for regulering er at reguleringen blir raskere. Primærregulatoren vil raskere oppfatte endring i forstyrrelser og innsvigningstiden reduseres ved endring av forstyrrelser (Trond Andresen (2016)) (Jonsson (2014)).



Figur 3.3: Blokkdiagram for kaskadereguleringsløyfe (Trond Andresen (2016), illustrert L. Hammer).

3.1.2 Regulering med kompensering

I regulering med kompensering brukes en eller flere forstyrrelser på systemet til å bestemme pådraget i reguleringsløyfa. Forstyrrelsene blir målt og den/deres verdi gir graden av påvirkning sammen med settpunktet. I figur 3.4 vises reguleringsløyfe som benytter foroverkobling for å kompensere for forstyrrelsene. Foroverkobling er effektivt for systemer der det er store prosessforsinkelser. Der den målte regulerte tilstanden ikke gir hurtig nok indikasjoner på forstyrrelsens påvirkning. Foroverkoblingen sørger derfor for å ta med forstyrrelsens innvirking tidlig i prosessen (Trond Andresen (2016)).



Figur 3.4: Blokkdiagram for foroverkopling med tilbakekopling (Trond Andresen (2016), illustrert L. Hammer).

3.2 Vanlige regulering- og styringsteknikker for kjøling

De vanligste styrings- og reguleringsteknikkene for romkjøling og ventilasjonskjøling er definert i tabell 3.1. *R* står for regulering mens *S* står for styring.

Tabell 3.1: Vanligste reguleringsteknikker for romkjøling og ventilasjonskjøling (Dokka (2013)).

Type	S/R	Forklaring
Konstant tilluftstemperatur	S	Tilluftstemperaturen er konstant, derav er det åpen sløyfestyring. Kjølebatteriets pådrag er gjerne sekvensstyrt med varmegjenvinner og varmebatteri. På denne måten produserer man ikke varme som kjølebatteriet må ta bort. Teknikken brukes oftest for ventilasjonskjøling.
Utetemperaturkompensering	S	Tilluftstemperaturen er styrt etter målt utetemperatur. I dette tilfellet brukes en utetemperaturkompenseringskurve som antar lineær sammenheng mellom tilluftstemperatur og utetemperatur. Både romkjøling og ventilasjonskjøling benytter ofte utetemperaturkompensering.
Avtrekkregulering	R	Tilluftstemperaturen for ventilasjonen reguleres etter avtrekkstemperaturen i ventilasjonsanlegget.
Avtrekkskompensering	S	Bruker kurve der tilluftstemperatur er en lineær funksjon av målt avtrekkstemperatur.
Romtemperaturregulert	R	Målt innetemperatur sammenlignes mot kjølingssettpunkt.

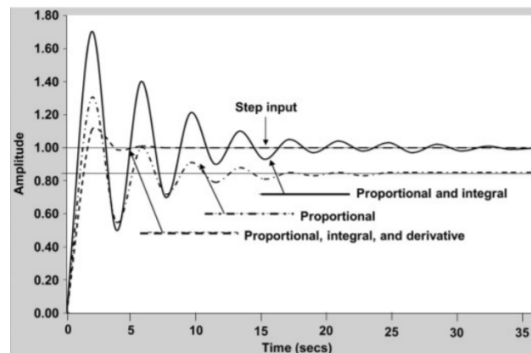
3.3 Regulatorer

En regulator er den fysiske komponenten som beregner nødvendige påvirkningen av systemet for å oppnå ønsket tilstand. Basert på dette gir regulatoren ut et reguleringsignal til ett pådragsorgan. Pådragsorganet kan være motorventil i kjølesystemet. Disse endrer tilstanden slik at avviket nulles ut (Hammer (2019)).

Det finnes ulike typer regulatorer. Tre typer regulatorer er essensielle i reguleringsteknikk.

1. Proporsjonal regulator(P): Handling proporsjonal med regulert tilstand. Skaper reguleringsavvik, se figur høyt striplet kurve.
2. Proporsjonal-integrasjons-regulator(PI): Utfører samme handling som P-regulator men annullerer reguleringsavvik, se figur 3.5 fet kurve.
3. Proporsjonal-integral-derivasjonsregulator(PID): Utfører samme handling som PI-regulator men stabiliserer signingene til responsen, se figur 3.5 middels striplet kurve (Sharma (2017)).

I figuren 3.5 illustreres også hvordan responsen til de tre regulatorene varierer. Blant annet kan man se at P-regulatoren stabiliserer seg med et avvik fra ønsket tilstand. Samtidig, er det illustrert forskjellen mellom topppunktene ved PI-regulator og PID-regulator (Sharma (2017)). Unøyaktig regulering kan medføre reguleringstap. Reguleringstap er energitap på grunn av unøyaktig regulering eller fordi utstyret benyttet ikke kan reguleres optimalt (Behrooz et al. (2018)).



Figur 3.5: Stegrespons for P-,PI- og PID-regulator(Sharma (2017))

Prognosestyring og -regulering

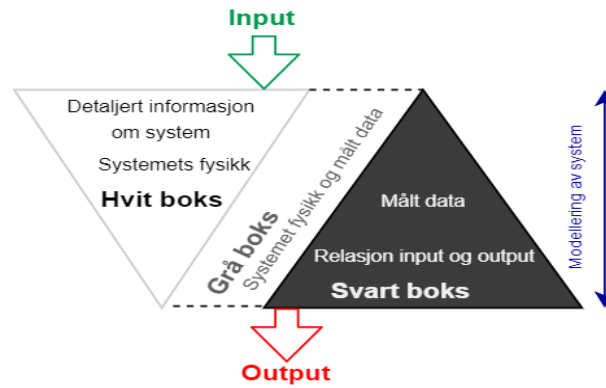
4.1 Prognosemodellregulering

Prognosemodellregulering (MPC) bruker en forenklet modell av et system for å predikere fremtidige tilstander og optimere driften av systemet. Systemet kan eksempelvis være et kjøleanlegg, bygg og/eller en lagringstank. Tanken er at i tilfellet man vet noe om fremtidige systemforstyrrelser kan modellen predikere utviklingen til systemet og kompensere for disse fremtidige forstyrrelsene før de forekommer (Hammer (2019)). Ulike retninger innenfor modellering som relevant for MPC er hvit-boks, grå-boks og svart-boks.

Regulatoren MPC består av et optimaliseringsproblem og modeller av bygget eventuelt ventilasjon varme og sanitær systemet (VVS-systemet). Optimaliseringsproblemet blir løst over en definert tidsperiode og bruker objektfunksjoner for eksempelvis energipriser, spisslast eller værdata (Ma et al. (2012)).

4.1.1 Hovedgrupper innenfor modellering

En modell er en representasjon av et fenomen i virkeligheten. I modellering skilles det mellom statiske- og dynamiske modeller. Statiske modeller har statiske betingelser. De brukes i tilfellet alle interne og eksterne input er kontrollerbare og output er tidsuavhengig. Dynamiske modeller omhandler endringene av interne og eksterne input for ett system der output er tidsavhengig. Statiske og dynamiske modeller inndeles i tre ulike retninger avhengig av valgt struktur for modellene, grå-boks-, hvit-boks- og svart-boks modellering (Fatima Amara1 (2015)). I figur 4.1 illustreres sammenhengen mellom hvit-, grå-, og svart-boks modellering.



Figur 4.1: Hvit-boks, grå-boks og svart-boks modell (Fatima Amara1 (2015), illustrert L. Hammer).

Hvit-boks modellering

Hvit-boks modeller baseres på fysiske prinsipper. Modellene er komplekse og krever detaljert informasjon om fysikken til bygningssystemet. Det forutsettes at all informasjon om systemet er tilgjengelig. Den matematiske representasjonen av relasjonen mellom parametere i modellen kan være ordinær, partiell, lineær og ikke-lineær differensial likning. Disse likningene er ofte basert fagfeltet varme-og masseoverføring, eksempelvis varmeledningslikningen av Fourier. Grunnet kompleks modellstruktur og bruk av store mengder informasjon er ofte simuleringstiden til disse modellene lengre enn for de to andre hovedgruppene, se figur 4.1 for illustrasjon av forskjellen mellom de tre metodene. Komplexiteten og bruk av tilgjengelig informasjon avhenger av presisjonen til modellen. I tilfellet det er nødvendig med høy presisjon krever det mye informasjon og detaljert fysisk modellering (Fatima Amara1 (2015)).

Grå-boks modellering


Grå-boks modellering er en forenkling av hvit-boks modellene, se figur 4.1. Disse modellene kombinerer kunnskap om fysikk og modellstruktur med målt systemdata. Modellene har oftest kortere simuleringstid sammenlignet med hvit-boks modellene(Homod (2013)). De fleste grå-boks modellene modelleres ved bruk av differensiallikninger. Differensiallikningenes oppbygning er basert på fysiske prinsipper, eksempelvis første-ordens differensiallikning for energibalanse til et bygg. I motsetning til hvit-boks modellene, har parameterne til grå-boks modellene både en empirisk og fysisk tolkning og de er bestemt basert på historisk måldata. I tillegg illustreres modellene gjerne grafisk ved hjelp av termiske nettverk og ikke bare ved differensiallikningene alene. Disse nettverkene bruker resistanser og kapasitanser i analogi med elektriske nettverk. Ett eksempel på metode for å modellere de termiske nettverkene er tilstand-rom modeller. Blant annet i programmeringsspråket matlab kan det benyttes bibliotek som estimerer parametere for resistanser og kapasitanser og setter de sammen i en modell. Parametere i differensiallikningen uttrykkes ved bruk av matriser. I dette biblioteket kan også modellen omgjøres fra kontinuerlig domene til diskret.

Svart-boks modellering

Modellstrukturen til svart-boks modellene avhenger av relasjonen mellom input og outputparametere. Den kan være dynamisk, statisk, lineær og ikke-lineær. Svart-boks modellering kjenner ikke fysikken til systemet og baserer seg ene og alene på målt data. Kalibreringen av svart-boks parameterne forgår automatisk ofte basert på lineær regresjon eller bakpropagering med empirisk data. Dette er den største fordelene for grå-boks modellene sammenlignet med hvit-boks modellene. Ulempen er imidlertid at både modellstrukturen og parameterne har liten fysisk tolkning. Presise svart-boks modeller krever store mengder empirisk data for nøyaktig kalibrering av parameterne. Når modellene er dynamiske kan de modelleres ved bruk av nevralt nettverk og transferfunksjoner. Simuleringstiden for svart-boks modellene avhenger av valgt modellstruktur og er ofte mye lavere enn for både grå-boks og hvit-boks modeller (Fatima Amara1 (2015)).

Nevrale nettverk


Nevrale nettverk er eksempel på svart-boks modellering. De er bygd opp av ulike lag med nevrone. Oppbygningen er basert på strukturen til det biologiske nervevevet i kroppen. Nevrale nettverk er et anerkjent verktøy i maskinlæring og kalles ofte selvlærende flerlagsnettverk. Disse nettverkene bruker empirisk data sammen med selvlæringsalgoritmer som kartlegger mønstre og skaper ett trent nettverk for ønsket system. Det trente nettverket blir en modell for systemet.



Figur 4.2: Oppbygningen til flerlagsforovernett (Kumar et al. (2013)).


For det mest vanlige nettverket, Forovernett(feedforward net), se figur 4.2. Forovernett har lag med nevrone, aktiveringsfunksjoner, vekter(w_i) og bias(b), se figur 4.3. Nevronene kjører en bestemt aktiveringsfunksjon. Input for hvert nevron har en tilhørende vektning og aktiveringsfunksjon. Vektingen sier noe om viktigheten til input-verdien.

Aktiveringsfunksjonen(ϕ) prosesserer summen av input og tilhørende bias. Biasen fungerer som ett konstant pådrag for å opprettholde en øvre/nedre grense (Lønsethagen (2019)).



Figur 4.3: Oppbygningen til kunstig nevron (Lønsethagen (2019)).

Aktiveringsfunksjonen er også kalt overføringsfunksjon. Den prosesserer overføringen input til output og beskriver outputen til nevronet. Ulike aktiveringsfunksjoner kan benyttes, vanligste er sigmoid funksjon, se figur 4.4.



Figur 4.4: Aktiveringsfunksjon Sigmoid. (Næs et al. (1993)).

Antall lag i forovernett varierer. Det første laget tar inn input og kalles input-laget. Siste laget gir ut output og kalles output-laget. Lagene i mellom de to kalles skjulte lag. Flerlagsforovernett har mer enn ett skjult lag. Antall skjulte lag vil variere fra nettverk til nettverk og avhenger av input- og output verdier som nettverket trenes etter. Presisjonen til ett nettverk avhenger av antall skjulte lag, antallet nevroner i hvert lag, valg av input og output, aktiveringsfunksjoner og treningsalgoritmer. I tilfellet nettverket er dimensjonert med for mange skjulte lag vil det slite med å konvergere (Kumar et al. (2013)).

Kalibreringen og valideringen av forovernett skjer ved bruk av måledata for input og output-verdier for trenings-, test- og valideringperiode. Under treningen bestemmes vektene og biasene til nettverket basert på inputen og outputen som sendes inn. Vanlige treningsalgoritmer er “Levenberg-Marquardt med backpropagation”, “Bayesian Regularization” og “Gradient Descent”. Valg av input og output er en av de faktorene som påvirker hvor nøyaktig nettverket vil bli. I tillegg vil valg av treningsfunksjon og aktiveringsfunksjoner avgjøre presisjonen til nettverket. I dag benyttes ulike aktiveringsfunksjoner avhengig av hensikten til nettverket (Matlab R2019b (2019b)).

Statistiske indikatorer for modellens treffsikkerhet

Det er ulike statistiske evalueringsindikatorer for treffsikkerheten til modeller. Indikatorene sammenligner målte faktiske verdier med simulerte verdier fra modellen. Basert på denne sammenligningen gir de en verdi som sier noe om treffsikkerheten til modellen.

”Mean square error”(MSE) er gjennomsnittlig kvadratisk avvik. Verdiene til indikatoren er alltid lik eller større enn null. I tilfellet MSE er lik null er treffsikkerheten til modellen tilnærmet perfekt. Størrelsen er imidlertid ikke normalisert noe som gjør at verdiene kan ha ett stort intervall. MSE er definert i funksjon 4.1 (Matlab R2019b (2019a)).

$$MSE = \frac{\|X - X_{ref}\|^2}{N_S} \quad (4.1)$$

Normalisert gjennomsnittlig kvadratisk avvik, også kalt “Normalized mean square error”(NMSE) normaliserer verdiene. Dette gjør at indikatoren varierer mellom $-\infty$ til $+1$, der nedre verdi er liten treffsikkerhet mens øvre er god. Indikatoren er definert i funksjon 4.2 (Matlab R2019b).

$$NMSE = 1 - \frac{\|X_{ref} - X\|^2}{\|X_{ref} - \bar{X}_{ref}\|^2} \quad (4.2)$$

“Mean absolute error”(MAE) beholder enheten til prediksjon og faktisk verdi. Den gir en tolkning av differansen i den faktiske enheten til størrelsen som predikeres, eksempelvis ved temperatur kan enheten være grader celsius (Chai and Draxler (2014)).

$$MAE = \frac{1}{n} \sum_{t=1}^n |X_{ref} - X| \quad (4.3)$$

“Root mean squared error”(RMSE) er kvadratrotten av summen til kvadrert avvik mellom referanse og predikert verdi delt på antall verdier (Chai and Draxler (2014)).

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (X_{ref} - X)^2} \quad (4.4)$$

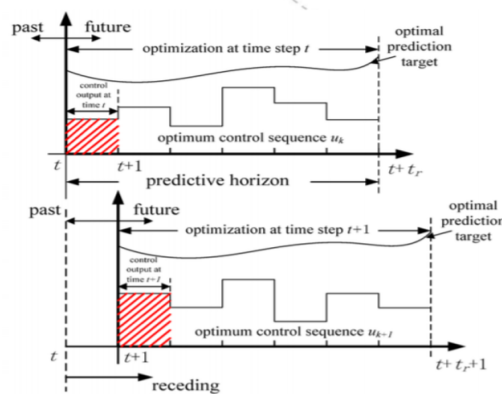
Normalized Root Mean Squared Error”(NRMSE) varierer mellom $-\infty$ til $+1$. Kvadratrotten benyttes i denne indikatoren for å skalere feilverdiene i samme intervall som ønsket verdi. I tilfellet modellens simuleringverdier passer perfekt med ønskede verdier er NRMSE 1, mens negativ uendelig indikerer lav treffsikkerhet. Indikatoren kan brukes for å sammenligne forskjellige modeller med ulik skala for observerte verdier. Denne er definert i funksjon 4.5 (Matlab R2019b).

$$NRMSE = 1 - \frac{\|X_{ref} - X\|}{\|X_{ref} - \bar{X}_{ref}\|} \quad (4.5)$$

4.1.2 Prognose- og reguleringshorisont

I figuren 4.5 illustreres tidssteg for rekalkulering av optimaliseringsproblemet og modell output i MPC-en. Løsningen for optimaliseringsproblemet og modellen kalkuleres i faste intervaller, dette kan være 15 minutter, en time eller mer. Disse faste intervallene kalles reguleringshorisonten. Løsningene er over en prognosesperiode, kalt prognosehorisont. I figur 4.5 er prognosehorisonten $t + tr$, eksempelvis bruker man prognose en uke frem i tid. Så ved tidspunkt t løses optimaliseringsproblemet, som brukes videre i regulatoren for å regulere eksempelvis innetemperatur(Hammer (2019)).

Slik fortsetter regulatoren å optimalisere den regulerte tilstanden for hvert tidssteg. Tidsstegene sørger for kontinuerlig justering av eventuelle avvik på grunn av unøyaktigheter og forenklinger i grensebetingelser og modell (Burant (2017)).



Figur 4.5: Tidssteg og prognosehorisont (Burant (2017)).

4.1.3 Studier med prognosemodellregulering av kjølesystemer

I 2014 ble det gjennomført et studium med MPC av kjølesystem og oppvarmingssystem til ett bygg i Pittsburgh USA. Studiet benyttet seg av modeller til bygget og tekniske installasjoner til varme og kjøling. I tillegg bestod MPC-en av ett optimaliseringsproblem med betingelser for gitte reguleringsparametere. Ulik prognosedata ble benyttet i MPC-en, værprognose, prognose av personbelastning og PID regulator. Bygget med tekniske installasjoner ble grå-boks modellert ved bruk av termiske nettverk basert på varmebalanser og kjente teoretiske sammenhenger for varmeoverføring. Prognosedata ble brukt som input var blant annet utetemperatur, solinnstråling og vind hastighet. Kjølesystemet bestod blant annet av viftekonvektorer og luft til luft varmepumpe. I modellvalideringen kommer det frem at ved hjelp av MPC, hyppig innhenting av prognose data (hvert minutt) møtes settpunkt for sonene oftere og energibruken til kjøling er redusert 17.8 prosent (Dong and Lam (2014)).

Et annet studium fra 2018 av Pang et. Al. fra Berkeley California med testanlegg for kjølesystem, med isvannsmaskin og gulvkjøling, ble MPC implementert for å optimalisere energibruken til kjøling. Den overordnede modellstyringen bestod her av to hovedmoduler, modell identifikasjon og løsning av optimaliseringsproblemet til MPC regulatoren. Forstyrrelsene tatt med i optimaliseringsproblemet er blant annet utetemperatur, solinnstråling og interne laster som lys og personbelastning. Denne modellen bruker igjen en prognose tidshorisont. Modell identifikasjons delprosessen benytter seg av en grå-boks modell av bygget. Dette studiet ønsket å vise at mindre kompleks modellstyring er mulig samtidig som det er mulig å oppnå gode resultater. Testperioden ble 42 prosent av effektforbruket til pumping av isvann redusert, mens 16 prosent av energibruken til kjøling ble spart (Pang et al. (2018)).

I 2019, i Virginia USA, ble det gjennomført et studium av Eini m. fl. med læringsbasert MPC. Et kontorbygg med fire soner med kjøling, ventilasjon og oppvarming var i Energyplus modellert. Samtidig ble det programmert i matlab en modell for personbelastning og energibalanse for bygget, i tillegg til ett optimeringsproblem. Hovedformålet med MPC-en var å fastsette fremtidig kjøle-/oppvarmingssettpunkt for kontorene en time frem i tid. For modellering av MPC-en ble NARX-nettverk og termiske nettverk benyttet, altså svart-boks- og grå-boks modellering. Videre tok modellene inn værdi i form av utetemperatur, solstråling og forrige times settpunkt. Resultatene fra studiet viste at energibruken til kjøling ble redusert med 40 prosent (Eini and Abdelwahed (2019)).

Et litteraturstudium av Afam m. fl. fra 2014 konkluderer med samme som studiet til Pang et. Al., modellen må ikke nødvendigvis være kompleks og omfattende for at implementering av MPC kan gi resultater. Afram et. Al. viser til at den enkleste formen for MPC, med lineære betingelser, enkle forstyrrelser og enkle predikative modeller for laster kan gi både reduksjon i energibruk og effektforbruk. Slike modeller vil være mindre kostbare og enklere å implementere i bygget (Afram and Farrokh (2014)) (Hammer (2019)).

4.1.4 CASE - REMA 1000 Vagle

Et lagerbygg på Vagle, i nærheten av Stavanger, eid av Rema 1000 benytter seg av prognoser for regulering av energisystemet til bygget. Lageret var ferdig bygd i 2018 og har siden den tid vært operativt. For optimal fordeling av produsert og lagret energi har bygget både termisk lager, elektrisk batteri og solceller. Energisystemet reguleres ved bruk av en optimeringsalgoritme. Denne tar inn prognose av værdata, målte verdier og prognose av energipris for å finne optimale settpunkt eksempelvis for turtemperatur på isvannskrets og tilluftstemperatur på ventilasjon. Værdata oppdateres flere ganger i løpet av en dag. Energiprisen oppdateres hver 24 time. Samtidig ble det benyttet en "rullende horisont", slik at prognoser med optimaliseringsalgoritme blir oppdatert ved faste intervaller, tilsvarende prognosehorisont. For å bestemme påvirkningen av de ulike prognosene har ulike systemer blitt modellert. Blant dem er varmeanlegg, elektrisk varmtvannssystem, termisk lagring i basseng og kjølemaskiner. Disse ble modellert ved bruk av grå-boks metoden, empiriske modeller. (Gergely Marton (2019)).

For øyeblikket er ulike maksinlæringsmodeller under utvikling for å optimalisere modellreguleringen. Doktorgradsstudenten Sven Opalic, tilknyttet senter for Kunstig Intelligens Forskning (CAIR) ved Universitetet i Agder, forsker på hvordan å utvikle maskinlæringsmodeller for REMA 1000 lageret som har sanntidsregulering med redusert ressursbruk og høyere treffsikkerhet. Hovedformålet er å utvikle nevralt nett ved bruk av maksinlæringssteknikker som eksempelvis "Deep Reinforcement Learning", som kan lære seg miljøet til bygget og ta selvstendig optimale valg. På denne måten trenger det ikke bli benyttet optimering i reguleringen.

Rent operasjonelt er energisystemene til REMA 1000 Vagle avhengig av en digital platform og sentral driftskontroll(SD-anlegg) som kommuniserer. Den digitale platformen er utviklet av eSmart systems. Denne lagrer prognoser og utfører beregninger ved bruk av eksterne servere på Microsoft Azure plattform. Optimaliserte settpunkt blir så sendt fra den digitale platformen til SD-anlegget. Fra SD-anlegget justeres de aktuelle settpunkter for de tekniske installasjonene (Opalic (2019)).

4.2 Prognose regelbasertstyring

Den andre retningen innenfor prognosestyring/-regulering er prognose regelbasertstyring(PRBC). Denne reguleringsteknikken bruker predefinerte beslutningsregler for å optimalisere reguleringen eller styringen av ulike tilstander i ett system. Den regulerte eller styrte tilstanden kan eksempelvis være temperatursettpunkt. Beslutningsreglene er ofte basert på faktorer som termisk masse, bygningskropp og interne laster (Clauß et al. (2019)). Typisk utforming av reglene er "hvis noe forekommer utfør denne handlingen". Nattkjøling er ett eksempel på regelbasert sty-

ring. Nattkjøling utnytter bygningskroppens termiske masse til å kjøle ned bygningskroppen for lagring av kjøleenergi til neste dag (Marnk et al. (2011)). I tilfellet det er prognose som blir brukt, altså for PRBC vil typiske prognoser som blir brukt være prognose av vær, personbelastning og fremtidig strømpris (Hammer (2019)). Ettersom oppgaven hovedsakelig tar for seg modellbasert regulering vil ikke oppgaven gå dypere inn i dette temaet.

4.3 Generelt om værprognoser og strømprisprognose

For bruk av prognose til regulering er det viktig at prognosene har høy treffsikkerhet og validitet. Vanlige prognoser brukt i reguleringen er; vær-, elektrisitetspris-, personbelastning- eller utstyrsbelastningsprognose. De to førstnevne vil bli beskrevet i dette kapittelet.

4.3.1 Værprognosedata fra Meteorologiske institutt

Informasjonen relatert til værprognoser er basert på kommunikasjon med forsker Ivar Ambjørn Sierstad hos Meteorologiske Institutt og deres nettsider (Seierstad (2019)) (yr.no (2019)). Værvarslingsdata er gratis og kan hentes ved hjelp av meteorologiske institutt sin vær-API.

Værvarslingsmodeller

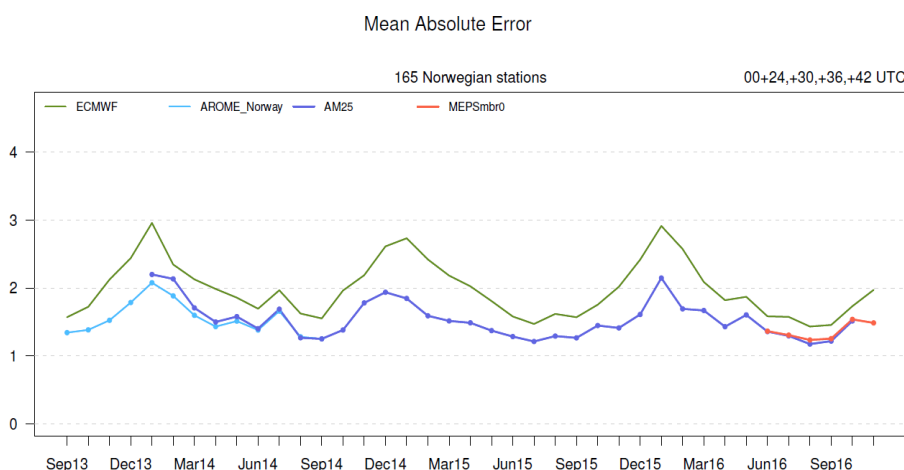
Værvarsling forekommer ved hjelp av en numerisk værvarselsmodell. De nyeste værobservasjonene benyttes for å beregne utviklingen til været frem i tid. Modellen benytter seg av ett tredimensjonalt rutenett. I hvert gitterpunkt i rutenettet beregnes alle værvariabler. Variablene kan være temperatur og skydekke. Avstanden mellom gitterpunktene avgjør nøyaktigheten til værprognosen. Kort avstand gir høy oppløsning og mer nøyaktig prognose.

Meteorologiske institutt sin korttidsvarsling bruker værvarslingssystemet Meteorological Cooperation on Operational Numerical weather prediction (MetCoOp EPS). Værvarslingsmodellen til dette systemet har operasjonelt vært i bruk siden 2013. Sammen med værvarslingsmodellen brukes en del avanserte statistiske metoder for å korrigere gjenkjennelige feil. Denne etter korrigeringen sørger for økt nøyaktighet. Korttidsvarselet til MetCoOp EPS varer over to til tre dager og har timesoppløsning. Prognose av utetemperatur oppdateres hver sjette time, mens global solstråling oppdateres hver 60-66 time (Seierstad (2019)). Korttidsvarslingen har detaljert oppløsning, med bredde lengde på 2.5 km i rutenettet (yr.no (2019)).

Langtidsvarsling bruker ensemble-systemet til European Centre For Medium-Range Weather Forecast (ECMWF-ENS). Langtidsvarslingen er sju til åtte dager. Oppløsningen på dette rutenettet er 18 km. Ettersom oppløsningen er høyere for langtidsvarslingen enn for korttidsvarslingen er treffsikkerheten lavere (yr.no (2019)) (Hammer (2019)).


Treffsikkerhet til værprognose

Metrologiske institutt produserer rapporter årlig om treffsikkerheten til utetemperatur kalkulert fra ECMWF-modellen. I 2010, 2015 og 2016 har det også blitt publisert rapporter som verifiserer både ECMWF- og MeetCOoP modellene. I figur 4.6 illustrerer MAE for utetemperatur predikert av værmodellene ECMWF, AROME Norway, MetCOoP(AM25) og MEPSmbro mot observerte data fra 2013 til 2016. Prognosen av utetemperatur er oppdatert hver sjettede time. MAE for MetCOoP ligger jevnt over lavere enn for ECMWF. I gjennomsnitt ligger utetemperaturen for perioden med gjennomsnittlig absolutt avvik på ca 1.5 grader celsius. Verdt å merke seg at MAE er høyere på vinterhalvåret enn på sommerhalvåret (Homleid et al. (2016)).



Figur 4.6: Gjennomsnittlig absolutt avvik for ECMWF, MetCOoP(AM25), AROME og MEPSmbro mot observerte data (Homleid et al. (2016)).

I figur 4.7 vises utetemperatur predikert og målt, i Oslo Blindern, 30.august 2018. Hensikten er å se hvor godt den predikerte utetemperaturen klarer å følge målt utetemperatur i løpet av noen få timer. Predikert utetemperatur har blitt hentet ut ved bruk av metrologiske institutt sin API(gjennom SD-leverandøren IWMAC), samtidig som observert utetemperatur har blitt målt lokalt. Parameteren uthentet er utetemperatur predikert 0-6 timer frem i tid. Grafen viser at predikert utetemperatur følger profilen til observert utetemperatur. Den predikerte utetemperaturen differensierer seg fra målt utetemperatur med en til to grader gjennom hele dagen (Meterologiske institutt; (2019a)) (Meterologiske institutt; (2019b)).

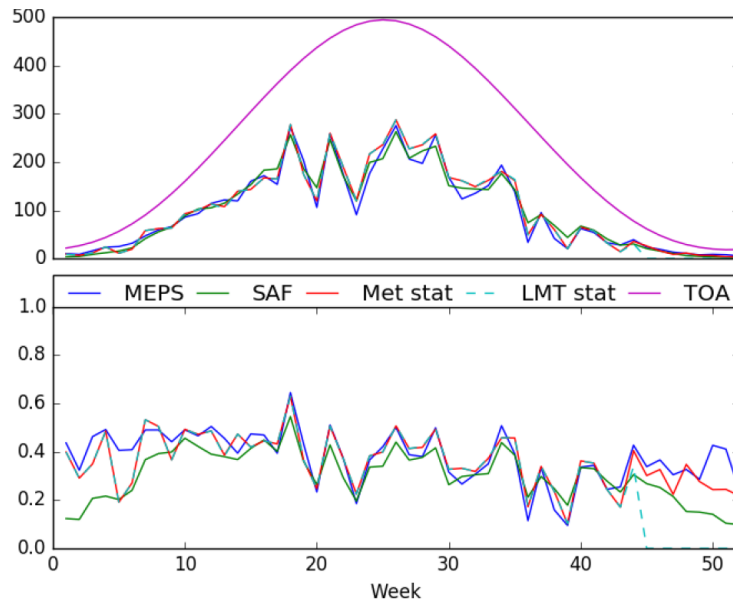


Figur 4.7: Prediksjon av utetemperatur en sommerdag (Meteorologiske institutt; (2019b)).

Solinnstråling

Metrologiske institutt sin værvarslingsmodell har både diffus og direkte solparametere. Strålingsvarslingen oppdateres hver 60 til 66 time (Seierstad (2019)). I følge forsker Seierstad hos yr.no har treffsikkerheten til solstårlingsparameterne blitt lite testet. Imidlertid påstår han at den er høy ettersom rekkevidden på rutenettet er bare 2.5 km, som er mye lavere enn for andre værvarslingsmodeller brukt for solstråling i Skandinavia, eksempelvis CAMS global forecasting har en 18 km rekkevidde.

I 2018 ble det publisert en rapport for å evaluere predikert global solstårling fra MetCOoP modellen. Metrologiske institutt sammenlignet målt med predikert global solstråling i 2017. Prognosen av den globale solstrålingen var oppdatert hver sjettede time. I figur 4.8 vises predikert(MEPS) sammenlignet med målt(Met) kortbølget direkte solinnstråling og klarhetsindeks. TOA står for den totale globale strålingen. I grafen viser det seg at den målte solstrålingen har større varians i prediksjonen sammenlignet med den predikerte. Den gjennomsnittlige MAE for timesverdier for MEPS modellen lå på $34,45 W/m^2$. I rapporten konkluderes med at det statistiske avviket ligger lavest på vinterhalvåret sør i landet. I løpet av sommeren er det mer sol og sjansen for store avvik er høyere. Klarhetsfaktoren er tatt med i figuren ettersom høy klarhet vil påvirke prognosen positivt. Klar himmel vil være avgjørende for at solinnstrålingen skal treffe jordas overflate (Kristiansen and Bakketun (2018)).



Figur 4.8: Solinnstråling Met(målte verdier) og MEPS(predikerte). (Kristiansen and Bakketun (2018))

4.3.2 Prognose av strømpris

Strømprisen i Norge er delt i to hovedgrupper, kraftpris og nettleie. Førstnevnte bestemmes av markedet og reflekterer forbrukt strøm. Sistnevnte er regulert og satt hos netteier og reflekterer kostnaden ved å eie ett strømpunkt. Etter “Forskrift om økonomisk og teknisk rapportering, inntektsramme for nettvirksomheten og tariffen” paragraf 14-2 består nettleien av ett fastledd, energiledd og effektledd. Førstnevnte dekker faste kostnader til netteier, som administrasjon. Energileddet dekker marginale tapskostnader som kostnad for frakt av energi. Mens sistnevnte, effektleddet (effektarriff) dekker kostnad for belastning av effektuttak på strømmettet (Energi-departementet (2019)).

Kraftpris

Den nordiske kraftbørsen for handel av elektrisitet er drevet av Nord Pool. Kraftprisen til elektrisitet er bestemt av tilbudet og etterspørselen i kraftmarkedet. Tilbyder, produsent av kraft og etterspørter, kjøper av kraft, byr på elektrisitetsprisen (spot-pris). Basert på budrunden mellom de to partene defineres kraftpris for neste dag time for time. Klokkene 12 hver dag lukkes budrunden og 12.45 blir kraftprisene for neste dag publisert. Derav blir en 24 timers prognose av kraftpris publisert en dag i forkant hver dag (NordPol (2019)). Treffsikkerheten til kraftpris 24 timer frem i tid vil derfor være 100 prosent. Dette gjør at kortsiktige prognoser av kraftprisen vil bli treffsikre og korrekte.

Effektarriff

I Norge er det pålagt effektarriff på nettleien også kalt effektledd. I henhold til forskriften om nettleie skal effektarriffene være basert på kundens effektuttak i definerte perioder. Effektuttaket er snittet effekt over en time for måledata hentet fra Elhub (database for måledata). Samtidig skal effektarriffen defineres i henhold til lavspenning- og høyspenningsuttak (Olje- og Energi-departementet; (1999)).

I november 2017 kom Norges vassdrags- og energidirektorat (NVE) med høringsforslag for

næringskunder. Forslaget innebar at effekttariff for næringskunder skulle videreføres, og at det skulle benyttes en såkalt abonnert effekt (Hansen et al. (2017)). Abonnert effekt betyr at den enkelte kunde setter en øvre grense for standard pris for effektuttak, uttak over denne grensen medfører en høyere effekttariff. Høringsforslaget har imidlertid fått en del tilbakemeldinger fra netteiere om at det ikke var nok fokus på tidsdifferensierte priser for både næringskunder og privatkunder. Derfor skal NVE komme med nytt høringsforslag. Høringssvarene fra blant annet Hafslund har vært at det nye høringsforslaget bør legge mer fokus på økte effektpriser i perioder med høy belastning i strømmettet. En slik regulering av kunders strømbruk vil kunne sørge for mindre ubalanse på strømmettet som igjen vil kunne gi lavere behov for utbygging (Johannessen (2018)). I tilfellet man kan bruke informasjon om når høye effekttariffer inntreffer kan prognose av effekttariffen sørge for økonomiske besparelser, hvor store besparelser vil avhenge av hvilke regler som blir satt for effekttariffene i fremtiden.

Metode

5.1 Hypotese

I analyse av hypotesene vil to modelleringsteknikker sammenlines. Første er grå-boks modellering, i form av termisk nettverk. Andre er svart-boks modellering gjennom to nevralt nettverk. Det er definert to hypoteser for resultat- og analysedelen:

1. Det er mulig å predikere kjølebehovet til et standardisert kontorbygg.
2. Avhengig av valgt modelleringsteknikk for bygget vil treffsikkerheten til prediksjonen av kjølebehov og innetemperatur variere.


Antakelser tatt for prognosemodeller:

1. Treffsikkerheten til værprognoser brukt i analyse er 100 prosent.
2. Bare en kontorcelle har blitt analysert som bygningskropp.
3. IDA ICE modell har blitt brukt som virtuell eksperiment. Responsen til IDA ICE modellen antas som realistisk respons for tilsvarende modellert bygg i virkeligheten.
4. Interne laster har blitt basert på standardverdier fra SN/TS 3031.
5. Midlere effekt igjennom en time tilsvarer maksimal effekt for kjøling.

5.2 Modell for standardisert kontorbygg i IDA ICE

Det har blitt modellert ett standardisert kontorbygg i IDA ICE for å utvikle MPC prognosemodeller, se figur 5.1. Plan- og fasadetegning har blitt basert på en standardisert modell for kontorbygg i Sintef sin ZEB prosjektrapport "A zero emission concept analysis of an office building", se figur 5.2 (Dokka et al. (2013)). Termiske parametere for bygningskroppen og internelaster

har blitt basert på SN/TS 3031 og TEK 17. IDA ICE modellen ble basert på standardverdier og minimumskrav for å representere ett standardisert kontorbygg. IDA ICE modellen brukes som ett virtuelt eksperiment. Simuleringsresultatene fra modellen representerer målverdier for prognosemodellene (Hammer (2019)).



Figur 5.1: Modellert standardisert kontorbygg i IDA ICE.

5.2.1 Bygningssimulerings programvare

Bygningssimuleringsprogram IDA Indoor Climate and Energy (ICE) 4.8 har blitt brukt for å modellere virtuelt eksperiment til oppgaven. Programmet er utviklet av det svenske selskapet EQUA Simulation AB. Det har blitt validert mot blant annet ASHRAE 140, CEN Standard EN 15255 og 15265. IDA ICE er spesielt egnet for dynamiske simuleringer og benytter likningsbasert modellering og Neutral Model Format (NMF). Programmet blir blant annet brukt til å analysere energibehov, energibruk og inn klima. Programmet er velegnet for modellering av bygninger med flere soner. Tidsoppløsningen til simuleringene utført i programmet kan inndeles helt ned til sekunder og man kan blant annet analysere energibehov og energibruk over flere år, dager, timer eller egendefinert periode(AB (2019)).

5.2.2 Termiske soner

Etter SN/TS 3031 skal termiske soner inndeles etter bygningskategori, bruksmønster, oppvarmings- og kjølebehov, ulikt interne varmetilskudd i forskjellige deler av bygningen, ventilasjonsbehov, ulike tekniske installasjoner, ventilasjons- og kjøleanlegg og belysningssoner (Standard-Norge (2016)). I figuren 5.2 vises tredje etasje fra Sintef sin ZEB prosjektrapport for standardisert kontorbygg. To termiske soner har blitt rødmerket med ett kontor mot nord og ett kontor mot sør. Av totalt 39 soner over fire etasjer høyt standardisert kontorbygg ble disse to sonene valgt som virtuelle eksperimenter. Sonen med høyest kjølelast i hele modellen var sørvendt kontorcelle. Fokuset har vært forskjellig orientering av sonen og areal størrelse. De har blitt delt opp etter nord og sør retning for å ta hensyn til passive soltilskudd. Etter SN/TS 30301 kunne de enkelte kontorcellene blitt slått sammen og skilt hovedsakelig mot nord og sør. Imidlertid er dette ikke valgt i analysen. Årsaken til dette er at det er ønskelig å fokusere på et høyt detalj nivå, samtidig ettersom internlast og behov ville bare blitt antall kontorceller proporsjonale er det valgt å analysere den enkelte kontorcelle separat. I tillegg, kontorcellene er separat i virkeligheten og dens modellering vil nok være nærmere virkeligheten med slik inndeling.



Figur 5.2: Termiske soner (Dokka et al. (2013)).

5.2.3 Bygningskroppen

I tabellen under kan vises verdier for bygningskroppen. Disse er blant annet basert på minimumskrav fra TEK17(Byggkvalitet (2017)).

Tabell 5.1: Verdier for bygningskroppen

Type	Verdier	Spesifikasjon
Yttervegger	$U=0.14 \text{ W/m}^2\text{K}$	200 mm isolasjon.
Yttertak	$U=0.14 \text{ W/m}^2\text{K}$	250 mm isolasjon.
Gulv mot kjeller	$U=0.11 \text{ W/m}^2\text{K}$	300 mm isolasjon.
Vinduer	$U=0.75 \text{ W/m}^2\text{K}$	Tre-lags lavenergi vindu
Dører	$U=0.75 \text{ W/m}^2\text{K}$	Godt isolert dør.
Normalisert kuldebroverdi	$0.10 \text{ W/m}^2\text{K}$	Basert på Tabell B.2.3 SN/TS 3031.
Lufttetthet	$N50 < 0.6 \text{ ved } 50 \text{ Pa}$	-

5.2.4 Interne varmetilskudd

Interne varmetilskudd for belysning, teknisk utstyr og personbelastning er basert på SN/TS 3031. Varmetilskuddet fra belysning og teknisk utstyr er basert på tabell A.6 og A.3. Personbelastningen er basert på tabell A.5. Etter NS 3701 er det antatt minimum 5 m^2 per person i bruksområdene, altså to personer i kontorcelle (Standard-Norge (2016)).

5.2.5 Inneklima - Kjølesettpunkt

For å opprettholde akseptabel termisk komfort har kjølesettpunkt blitt tatt fra standarden NS/TS 3031. Kjølesettpunkt er satt til 24 grader celsius (Hammer (2019)). Dette settpunktet henspiller veiledning 444. til arbeidstilsynet med maksimal grense på operativ temperatur i sone på 26 grader celsius (Arbeidstilsynets veiledning 444 (2012)).

5.2.6 Ideelle kjølere for kjølebehov

I IDA ICE modellen ble ideelle kjølere brukt for å analysere kjølebehov. For å sikre ideell simulering ble kjøleytelsen satt lik en og maksimal installert effektkapasitet satt til 10 000 W. Dette for at den skulle være høy nok til å dekke behovet for alle tilstander. Den ideelle kjøleren ble plassert i kontorcelle. Realistisk energibehov til kjøling med systemtap har ikke blitt tatt med IDA ICE modellen. Reguleringen av de ideelle kjøleenhetene er idealisert PI-regulering(urealistisk). Slik ideell simulering gir kjølebehovet til modellen og dette er hovedfokus i oppgaven (Hammer (2019)).

5.2.7 Klimafil for IDA ICE

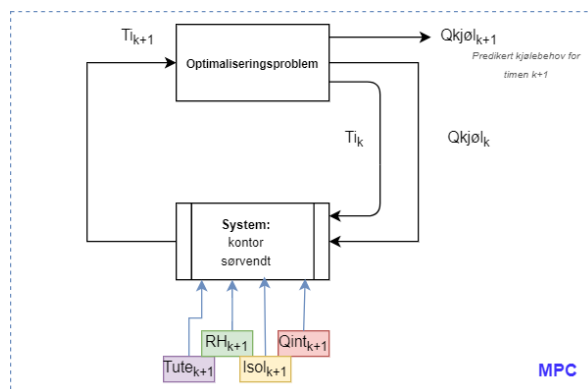
For å beregne kjølebehovet til modellen trenger IDA ICE værfiler med korrekt data for året som blir analysert. Valgt lokasjon for modellen er Blindern, Oslo. Årsaken til at Blindern ble valgt er sentral beliggenhet i Norge og tilgang på store mengder historisk værdata fra Meteorologiske institutt. Utetemperatur og relativ fuktighet ble derfor hentet derfra (Institutt (2019)). Parametere for solinnstråling ble derimot hentet fra Copernicus Atmosphere Monitoring Service(CAMS) sin database. Det var to solinnstrålingsparametere som ble hentet ut direkte normal solstråling og diffus horisontal solinnstråling. Alle værparametere ble satt sammen i en fil for IDA ICE for året 2018(Hammer (2019)).

5.3 Utviklet prognosemodellregulering for kjølebehov

Det er utviklet tre modeller for MPC av kjølebehov. En modell ved bruk av flerlagsforovernett(FN), to modeller ved bruk av tilbakevendende nettverk(NX og LRN) og en modell termisk nettverk(TN). Modellene har predikeringshorisont på 15 timer og reguleringshorisont på en time.

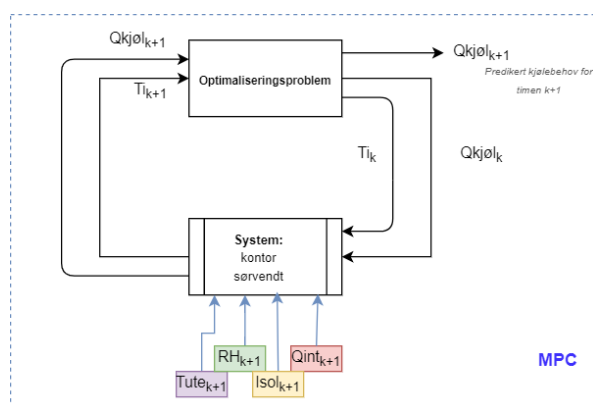
Modellene har enten ett nevralt nett eller termisk nettverk for bygget. Modellene har beregner inntemperatur og har en optimeringsalgoritme med betingelser for kjølestartpunkt og kjølekapasitet i løpet av en time. De nevrale nettverkene beregner også kjølebehov.

I figur 5.3 vises MPC oppbygningen mot termisk nettverk. Systemet, bygget, har input; kjølebehov og inntemperatur for tidspunktet k og prognose for utetemperatur, relativ fuktighet, solinnstråling og interne laster neste time. For tidspunktet $k=0$ er inntemperatur T_{i_k} og kjølebehov $Q_{kjøl_k}$ målt. Output for modellen er neste times inntemperatur, $T_{i_{k+1}}$. $T_{i_{k+1}}$ er input for optimeringsalgoritmen. Denne sammenlignes med startpunkt. Hvis inntemperaturen er høyere enn startpunktet er det kjølebehov for timen $k+1$. For gjentakelse av neste times prediksjon av inntemperatur er forrige predikerte inntemperatur og kjølebehov input til systemmodellen. Slik fortsetter modellen å predikere 15 timer frem i tid. Output av MPC-en er predikert kjølebehov.



Figur 5.3: Modell med MPC og tilbakekobling for termisk nettverk (Illustrert L. Hammer).

For de nevrale nettverkene som predikerer både kjølebehov og innetemperatur og benytter optimeringsalgoritmen for kontroll av innetemperatur og effektkapasitet kjøling er MPC illustrert i figur 5.4. Her er det samme input til systemmodellen. Forskjellen mellom denne mot nevrale nettverk og den mot termisk nettverk er prediksjon av kjølebehov, der det nevrale nettverket predikerer kjølebehov i systemmodellen. Denne blir imidlertid sjekket i optimeringsalgoritmen. For NX nettverket vil denne tilbakekoblingen være en funksjon av nettverket når nettverket er lukket. Dette gjør at prediksjonen over 15 timer kan komme direkte inn mot optimeringsproblemet i vektorform. Funksjonaliteten til optimeringsalgoritmen vil imidlertid kunne være den samme.



Figur 5.4: Modell med MPC og tilbakekobling for nevrale nettverk (Illustrert L. Hammer).

Valg av input-parametere til de tre modellene er basert på korrelasjonen mellom innetemperatur, kjølebehov og input-parametere. Det ble også vektlagt den fysiske tolkningen av relasjonen mellom output og input. I tabell 5.2 vises valgt input og output for de to modellene.

Tabell 5.2: Valgte output-variabel og input-parametere for system, bygg, modeller.

Type	Valgt variabel/parameter
Output	Innetemperatur [°C]
Output	Kjølebehov [W]
Input	Utetemperatur [°C]
	Relativ fuktighet [%]
	Global solstråling [W/m^2]
	Tidspunkt i løpet av dagen [time]
	Interne laster [W]
	Forrige times beregnede/målte kjølebehov [W]
	Forrige times beregnede/målte innetemperatur [°C]

For input- og output-verdier for utvikling av modellene ble simuleringsinput og resultater fra IDA ICE og klimafil benyttet.

5.3.1 Programmeringsspråk for utvikling av modeller og MPC

For utvikling av modellene har Matlab R2019b blitt benyttet. Matlab er et programmeringsspråk og programvare tilpasset forskning og ingeniørfag. Hovedfokuset til Matlab er numerisk matematikk. Det er profesjonelt utviklet og inneholder ulike apper/biblioteker for blant annet maskinlæring og modellering. Programmet har ett vidt bruksområde eksempelvis brukes det innenfor alt fra finansiell analyse til signal prosessering. I løpet av denne oppgaven brukes programmet til modellering og grafisk fremstilling i resultatdelen (Matlab R2019b (2019b)).

5.3.2 Optimeringsalgoritme til MPC utviklet til flerlagsforover nettverk

MPC delen i figur 5.3 benytter seg av lineær optimeringsproblem. Funksjonen til matlab *linprog* har blitt benyttet for å definere betingelser for optimeringen for FN nettverket, se figur 5.5 og appendiks 9.3.6. optimeringsalgoritme mot FN nettverk har blitt prioritert grunnet resultater i resultatdelen.

$$\min_x f^T x \text{ such that } \begin{cases} Aeq \cdot x = beq, \\ lb \leq x \leq ub. \end{cases}$$

Figur 5.5: Definisjon til *Linprog* - lineær programmeringsløser.

Hovedfokuset til optimeringsproblemet er å sørge for at målt/predikert inntemperatur er over kjølesettpunkt i tilfellet det er kjølebehov, samtidig skal kjølebehovet ikke overstige maksimal kapasitet. Maksimal kapasitet er bestemt av kjølebehovssimulering i IDA ICE for sonen.

Vektoren X tilsvarer tilstandsvariablene til optimeringsproblemet. De er i dette tilfellet innetemperatur(x_1) og kjølebehov(x_2). Vektoren f tilsvarer koeffisientene til X den er satt [1,1]. Definerer videre


tilstandsvariablene i funksjonen A_{eq} er satt til $[1 \ 0; \ 0 \ 1]$ mens b_{eq} er satt til $[T \ Q_c]$. Videre er det satt øvre og nedre grenser for de to tilstandsvariablene. Nedre grense for inntemperatur og kjølebehov er satt til 24 grader celsius og 0 Wh for kjølebehov. Øvre grense for innetemperatur og kjølebehov er satt til 100 grader celsius og 1200 Wh/h. Grensen på 100 grader celsius ble satt på grunn av at all målt innetemperatur over 24 grader skal gi kjølebehov. Tilfellet der innetemperaturen overstiger 100 grader er høyst usannsynlig, derfor brukes denne som en uendelig høy grense.

5.3.3 Egenskapene til modellene

Svartboks modeller - Nevrale nettene

For de nevrale nettene (NX, FN og LRN) er det definert en test-, trenings- og valideringsperiode. Samtidig velges det aktiveringsfunksjon, treningsfunksjon og antall skjulte lag. Valgene skal oppfylle lavest mulig statistisk avvik, NRMSE. Valgt aktiveringsfunksjon for skjulte lag for NX, LRN og FN er Log-Sigmoid overføringsfunksjon. Funksjonen er valgt ettersom den er anbefalt for læring av mønstre. I tillegg er flere aktiveringsfunksjoner testet og denne ga høyest nøyaktighet. For output-laget blir lineær overføringsfunksjon benyttet. Dette var fordi outputen for nettet ikke er binær. Treningsfunksjonen som blir brukt for de alle tre nettverkene er Levenberg-Marquardt med bakoverpropagering for bestemmelse av vekter og bias. Ved bruk av denne funksjonen vil en lineær kombinasjon av vekter med tilhørende standard feilverdier minimeres og så velges ut beste kombinasjon. Korresponderende matlab kode for FN, NX og LRN er i appendiks 9.3.2, 9.3.1 og 9.3.3.

Forskjellen mellom de tre nettverkene er tilbakekoblingene til de tilbakevendende nettverkene, se figur 5.6. For FN benyttes hovedsakelig foroverkobling mens for NX og LRN brukes både tilbakekobling og foroverkobling. NX nettverket bruker sine egne resultater fra output-laget til input-laget for prediksjon frem i tid. NX nettverket testes og valideres som åpent nettverk, som forovernettverk. Avslutningsvis lukkes nettverket med tilbakekobling for å predikere en horisont frem i tid, eksempelvis over prognosehorisonten. Dette gjør at NX nettverket kan fungere godt i en MPC. LRN benytter tilbakekobling mellom de skjulte lagene, fra output til input i skjult lag. Dette gjør at de skjulte lagene lærer av tidligere output.




Figur 5.6: Illustrasjon FN, NX og LRN (Matlab R2019b (2019b)).

Av inputverdiene som er gitt kommer det frem at vektene til nettverkene blir høyere for forrige times målte/beregnete innetemperatur og distribuert kjøling. Dette forteller at nettet bruker tidligere målte verdier for videre prediksjon til stor grad. Ved å følge med på forrige times målte/predikerte verdi kan nettet enklere si noe neste timens verdi.

Gråboks modell - Termisk nettverk

TN har fire input verdier; utetemperatur, solstråling, interne laster og forrige times kjølebehov. Nettverket er en første ordens differensial likning, R1C1 nettverk, se figur 5.7.



Figur 5.7: Termisk nettverk R1C1 (Illustrert L. Hammer).

Modelleringen av TN ble gjort ved bruk av matlab funksjonen ”*idgrey*” som definerer en tilstand-rom modell (state-space model). Tilstand-rom modellen definert kontinuerlig er gitt ved funksjon 5.1 og 5.2.

$$\dot{x}(t) = Ax(t) + Bu(t) + Ke(t) \quad (5.1)$$

$$y(t) = Cx(t) + Du(t) + e(t) \quad (5.2)$$

Input verdiene er gitt ved vektoren $u = [Tute, Qint, Qsol, Qkjøl]$. Vektoren D og K er initielt satt lik nullverdier. Variabelen e tilsvarende avviker mellom ”målt” og simulert verdi. Tilstanden $x = y$ er innetemperaturen i sonen. Koeffisienten C er estimert til 1.

Sonens initiale resistans $R1$ [W/K] er blitt definert ut fra gjennomsnittlig U-verdi for bygningen. Sonens initiale varmekapasitans $C1$ [W/K] har blitt estimert basert på rommets luftmengde, varmekapasitet og luftvolum. Matlab funksjonen *Greyest* har så estimert verdiene basert på inputverdiene fra klimafil og IDA ICE simulering. Avslutningsvis ble TN omgjort fra kontinuerlig til diskret domene. Årsaken til dette var timesverdier fra prognose. I appendiks 9.3.4 og 9.3.5 vises matlab koden som er brukt for det termiske nettverket.

5.3.4 Praktisk implementering av MPC

Ved bruk av en digital platform, online server og SD-anlegg kan MPC av kjølesystem forekomme. I den digitale platformen, som eksempelvis e-smart systems for REMA 1000 lageret, kan værprognoser og beregningsresultater innhentes. Simuleringer av MPC kan utføres av en online server med simuleringsskapasitet og resultatene kan lastes inn på digital platform. Fra den digitale platformen kan ferdige settpunkt sendes til SD-anlegget.

I løpet av denne metodedelen kommer det frem at kjølebehov er hovedfokuset til MPC-en. Denne MPC-en gir ikke ut settpunkter direkte. Derfor for praktisk gjennomføring må det spesifikke kjølesystemet for bygget modelleres for å beregne eventuell nødvendig settpunkt for


isvannstemperaturer enten for lager evt for turtemperatur fra kjølemaskin. I tilfellet kjøling av bygningskroppen(nattkjøling) benyttes kan settpunkt tilluftstemperatur benyttes.

Ved bruk av en av de nevnte nettverkene blir benyttet for modellering av systemmodellen til MPC-en bør det bli bestemt ett treningsintervall. Med andre ord at nettverket trenes eksempelvis hver tiende time for de nye måleverdiene fra bygget, målt innetemperatur og kjølebehov. Samtidig som historisk måledata benyttes.

Resultater

6.1 Valgt sone

En av to soner evaluert i IDA ICE modellen ble valgt videre for utvikling av MPC. I figur 6.1 vises kjølebehovsprofil for sør- og nordvendt kontor, for de to dagene de har høyest kjølebehov. For kontor mot sør inntreffer denne dagen i 8. august mens for kontor mot nord inntreffer den i 10. april. Kontor sør har høyest kjølebehov på sommerhalvåret. Fra varmebalansen til sonene er denne sonen mest påvirket av endringer i solinnstråling. På grunn av denne sensitiviteten til værforhold og høyt kjølebehov er sørvendt sone tatt med videre i analysen.



Figur 6.1: Kjølebehovsprofil for kontor mot sør og nord.

6.2 Sammenligning av grå-boks og svart-boks modeller

Tre nevrale nettverk, flerlagsforover-(FN), to tilbakevendende nettverk(NX og LRN), og ett termisk nettverk(TN) sammenlignes for å si noe om statistisk avvik mellom målverdier og simulerte verdier. Målverdiene er IDA ICE simuleringresultater. Målverdien til det FN, NX, LRN og TN er innetemperatur. Årsaken til at innetemperatur evalueres er at det termiske nettverket vil hovedsakelig predikere innetemperatur og benytte optimaliseringsalgoritmen til MPC-en til

å predikere kjølebehov. I motsetning vil de tre nevrale nettverkene predikere både inntemperatur og kjølebehov som vil direkte kontrolleres i optimaliseringsfunksjonen. FN bruker matlab funksjonen “*feedforwardnet*”. For NX har matlab funksjonen “*narxnet*” blitt benyttet. NX har blitt simulert med åpent nettverk i trening- og valideringsperioder. De to matlab funksjonene for NX og FN som sammenlignes har derfor relativt like egenskaper. NX blir imidlertid inkludert uavhengig av dette faktum, ettersom det er aktuelt å bruke det med tilbakekobling for prediksjon over prognosehorisont. LRN benytter seg av matlab funksjonen “*layrecnet*”. TN benytter matlab funksjonene “*greyest*” og “*idgrey*”.

For sammenlikningen av modellene har det blitt brukt to treningsperioder, 30 dager og 5 dager, gjeldende august og september for validering og trening. I tabell 6.1 vises treningsperiode 30 dager med valideringsperiodene 3 og 20 dager. Antall skjulte lag i FN, NX og RLN ble optimalisert avhengig av treningsperioden. I optimaliseringen av antall skjulte lag og nevroner ble divergens hensyntatt og unngått. For treningsperiode på 30 dager hadde nettverkene to skjulte lag med 10 nevroner i hvert lag mens for treningsperiode på 5 dager hadde nettverkene ett skjult lag med 8 nevroner i hvert lag. Det TN hadde samme oppbygning uavhengig av treningsperiode, bare selve lengden på treningsperioden blir endret.

Tabell 6.1: NRMSE med 30 og fem dagers treningsperiode

Modell	Treningsperiode 30 dager	Valideringsperiode 3 dager	Valideringsperiode 20 dager
LRN	0.461	0.301	0.333
NX	0.471	0.416	0.409
FN	0.566	0.323	0.525
TN	0.038	0.021	0.013

Modell	Treningsperiode 5 dager	Valideringsperiode 3 dager	Valideringsperiode 20 dager
LRN	0.065	0.005	-0.150
NX	0.088	0.073	-0.017
FN	0.098	0.056	-0.002
TN	0.283	0.172	0.007

TN er forenklet med en resistans og kapasitans, R1C1 nettverk. Det har lavere normalisert statistisk avvik for treningsperiode med 30 dager sammenlignet med 5 dager. Modellen presterer høyere med kortere treningsperioder.

Sammenlignet med de tre andre nettverkene har FN høyest NRMSE for treningsperiode 30 dager. Samtidig er treffsikkerheten til nettverket drastisk redusert med fem dagers treningsperiode. Dette indikerer at nettverket er sterkt avhengig av mengde input for trening.


NX og LRN nettverkene har relativt høy treffsikkerhet med treningsperiode på 30 dager. Samtidig er treffsikkerheten til nettverket relativt lav med fem dagers treningsperiode, slik som for FN. På lik linje som for FN ser nettverkene ut til å være avhengig av stor mengde input.

Laveste treffsikkerhet av det tre nevrale nettverkene var LRN. Nettverket benytter seg av tilbakekobling i de skjulte lagene. nettverket ligger lavere for alle treningsperioder og valideringsperioder sammenlignet med de to andre.

Oppsummert har det FN høyest presisjon for treningsperiode på 30 dager og oppnår den høyeste treffsikkerheten. Samtidig har NX nettverket relativt god presisjon sammenlignet med TN. For treningsperiode på 30 dager er treffsikkerheten til NX bare 9,5 prosent lavere. Derfor for å undersøke muligheten for høyere presisjon vil NX og FN nettverkene bli sammenlignet for lengre treningsperioder.

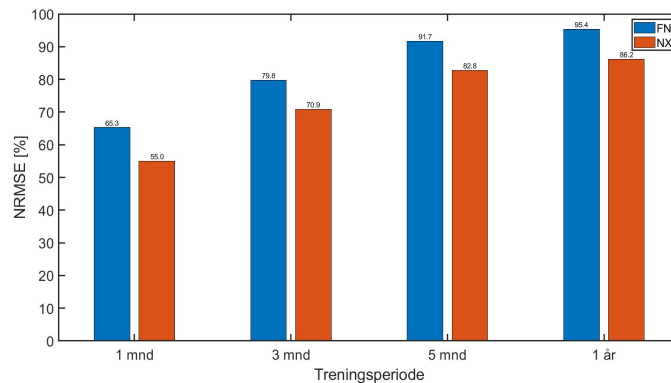
6.2.1 Treffsikkerheten til FN og NX over lengre treningsperioder

I avsnitt 6.2 hadde FN og NX høyere presisjon for lengre treningsperiode på 30 dager. I figur 6.2 og 6.3 er NRMSE plottet for FN og NX med treningsperiode august(1 måned), juni-juli-august(3 måneder), april-mai-juni-juli-august(5 måneder) og ett år. I figur vises NRMSE for begge nettverk for innetemperatur. Antall skjulte lag og nevroner ble optimalisert for hver treningsperiode. For en måned hadde begge nettverkene to skjulte lag med 10 nevroner. For tre måneder hadde de to skjulte lag med 15 nevroner i hvert lag. Antall skjulte lag for treningsperiode på fem måneder var to men med 20 skjulte nevroner. Avslutningsvis hadde nettverkene to skjulte lag med 50 og 40 nevroner.



Figur 6.2: Sammenligning NRMSE for innetemperatur, FN og NX med treningsperiode på en mnd, tre mnd, fem mnd og ett år.

I figur 6.2 vises NRMSE for FN og NX for innetemperatur med treningsperioder på en måneder, tre måneder, fem måneder og ett år. Treffsikkerheten til FN ligger godt over NX for alle treningsperioder. Differansen til NRMSE mellom FN og NX for treningperiode en måned ligger på 9,5 prosent. For ett år minker denne differansen, her er den nede på 2,5 prosent.



Figur 6.3: Sammenligning NRMSE for kjølebehov, FN og NX med treningsperiode på en mnd, tre mnd, fem mnd og ett år.

I figur 6.3 vises treffsikkerheten for begge nettverk for kjølebehov. Treffsikkerheten til FN ligger høyere enn NX for alle treningsperioder. Treningsperioden på 1 mnd har den høyeste differansen i NRMSE på 10,3 prosent. NX og FN har NRMSE på 86,2 og 95,4 prosent for treningsperiode på ett år. For ett år er det også lavest differanse i NRMSE på ca 9,2 prosent. Gjeldende for begge nettverkene er at de har økende treffsikkerhet med økt lengde på treningsperioden.

For sammenligning av kjølebehov og innetemperatur prediksjon for FN er NRMSE høyest for kjølebehov. Imidlertid er differansen ikke mer enn 0,8 prosent gjennom hele året.

6.3 MPC kjølebehov


For utvikling av MPC har optimaliseringsfunksjonen “*Linprog*” i matlab blitt brukt med betingelser for effektkapasitet kjøling på 1200 Wh/h og maksimal kjølesettpunkt på 24 grader celsius. Effektkapasiteten er bestemt av egen kjølelast simulering for sonen og er maksimal effektbehov for kjøling i løpet av året.

I analyse av modellreguleringsløyfe for kjølebehov har FN blitt brukt. Årsaken til dette er at modellen hadde høyest NRMSE for både innetemperatur og kjølebehov. FN nettverket som har blitt brukt har to skjulte lag, 50 og 40 nevroner. Valgt treningsperiode er ett år. I dette tilfellet har det ikke vært mulig å teste responsen til MPC i et bygningsmiljø. IDA ICE har ikke muligheten til å direkte simulere med matlab. I analysen er det derfor valgt å vise treffsikkerheten til modellene og se på prediksjonen til MPC-en over en prognosehorisont på 15 timer.

6.3.1 Dag med maksimal solinnstråling


For å se på treffsikkerheten til systemmodellen har dagen med høyeste solinnstråling blitt valgt for 2018. Årsaken til valget er ønsket om å se på prediksjonen ved avvikende værtilstand. Det nevrale nettverket er trent for ett år og validert med dagen med høyest solinnstråling dagen i løpet av 2018. FN har blitt optimalisert med to skjulte lag med 50 og 40 nevroner. I figur 6.4 vises predikert(simulert) innetemperatur sammenlignet med målverdi inntemperatur fra IDA ICE

modell. Differansen mellom predikert og målverdi er aldri høyere enn 0,07 grader. Treffsikkerheten til modellen for inntemperatur denne dagen lå på 73 prosent NRMSE.



Figur 6.4: Innetemperatur predikert og målverdi fra IDA ICE.

I figur 6.5 vises predikert(simulert) og målverdi for kjølebehov. Det predikerte kjølebehovet ligger noe lavere på tidspunktet kjølebehovet er på sitt maksimale, ellers følger det predikerte kjølebehovet målverdiene jevnt. Treffsikkerheten til predikert kjølebehovet for denne dagen lå på 91 prosent NRMSE.




Figur 6.5: Kjølebehov predikert og målverdi fra IDA ICE modell.

For å sammenligne NRMSE for innetemperatur og kjølebehov viser det seg at NRMSE til kjølebehov ligger betraktelig høyere enn for innetemperatur. Ved sammenligning av 6.4 og 6.5 vises også dette, predikert kjølebehov har tettere oppfølging av målverdi-kurven enn tilfellet for predikert innetemperatur.

6.3.2 Gjennomsnittlig dag og dag med maksimalt kjølebehov over prognosehorisonten


For å se på treffsikkerheten til MPC med prognosehorisont på 15 timer vil MPC av kjølebehov sammenlignes med målverdier fra IDA ICE modell. Lukket sløyfe basert på prinsippet i avsnitt 5.3 etter figur 5.3 har blitt testet. For hver sløyfe har predikert kjølebehov og innetemperatur blitt brukt videre for neste times prediksjon frem til siste femtende time. Dette betyr at 14 timer av prognosehorisonten, eksempelvis fra klokken 4.00 til klokken 18.00, benytter systemmodellen predikerte verdier for innetemperatur og kjølebehov som input. Det nevrale nettverket er trent for ett år.

For å se på en gjennomsnittlig sommerdag ble åttende august valgt. Dagen ble valgt basert på gjennomsnittlig kjølebehov fra IDA ICE modell månedene mai, juni, juli, august og september. I figur 6.6 vises prediksjon åttende august fra kl.3.00 til kl.18.00 hver time frem i tid. Rent grafisk følger predikert verdi tilnærmet 100 prosent målverdi frem til klokken 12, fra dette tidspunktet frem til klokken 17 ligger målverdi noe høyere enn predikert kjølebehov. Differansen på toppunktet klokken 15.00 utgjør ca 45 Wh/h. Total summert avvik i kjølebehov gjennom hele den gjennomsnittlige dagen er 155 Wh. Av total kjølebehov for de 15 timene den gjennomsnittlige dagen på 6762 Wh. Altså er det ca 2 prosent avvik totalt for summert energibehov til kjøling 15 timer frem i tid.



Figur 6.6: Prognose kjølebehov 15 timer frem i tid mot målverdi for kjølebehov. Fra kl 3.00 om morgenen frem til kl 18.00.

Dagen med høyest kjølebehov basert på IDA ICE modell er blitt brukt for å se på prediksjon med avvikende tilstand. I figur 6.7 ligger maksimalt kjølebehov kl 16.00 for målverdi tilnærmet 200 Wh/h høyere enn predikert. Predikert kjølebehov fra det nevrale nettet ligger jevnt lavere enn målverdi kjølebehov fra IDA ICE modellen. For prognose er totalt summert kjølebehov for dagen med maksimale kjølebehov er 6693 Wh. Total summert avvik mellom prognose og målverdi for dagen er 899 Wh. Altså er det 13 prosent avvik for dagen med maksimalt kjølebehov totalt for summert energibehov til kjøling 15 timer frem i tid.



Figur 6.7: Predikert kjølebehov 15 timer frem i tid mot målverdi for kjølebehov. Fra kl 3.00 om morgenen frem til kl 18.00.

Sammenligning av en gjennomsnittlig dag og en dag med maksimalt kjølebehov viser at prognose av kjølebehov ved reguleringshorisonten kl.3.00 har størst treffsikkerhet for gjennomsnittlig dag. Avvikende tilstand for dagen med maksimalt kjølebehov svekker treffsikkerheten til modellen. Avvik i nødvendig energibehov til kjøling differensieres mellom 2 til 13 prosent for de to dagene. Basert på værfilene viser det seg at solinnstrålingen for dagen med maksimalt

kjølebehov er høyere enn for dagen med gjennomsnittlig kjølebehov. Når det gjelder utetemperatur ser denne ut til å være relativt lik for begge dager.

Diskusjon

Diskusjon av litteraturstudiet om kjølesystem og regulering

Kjøle faktoren er høyere for lave utetemperaturer, noe som gjør at det er gunstig å produsere kjøling når utetemperaturen lav. Samtidig varierer kjøle faktoren med lasten på kjølemaskinen. Økt last på kjølemaskinen gir økt kjøleytelse. Dersom kjøle behovet kan predikeres med relativt høy treffsikkerhet kan kjølemaskinen kjøres kontinuerlig med høy last før kjøle behovet inntreffer. Dette gjør at maskinen kan driftes med mindre delast og høyere ytelse. Slik optimalisert drift av kjølemaskinen vil avhenge av blant annet prognose av kjøle behovet og utetemperaturen, samtidig som den produserte kjøle energien må kunne lagres. Lagringen er nødvendig fordi produksjonen med høy last og produksjon når utetemperaturen er lav sjeldent inntreffer på samme tidspunkt. Lagringen kan eksempelvis være i form av nattkjøling av den termiske massen til bygget eller energilagring i tank. For mest mulig effektiv lagring kan latent energilagring være løsningen. Lagring av energien vil også kunne sørge for kontinuerlig tilgjengelig kjøle energi som igjen kan redusere temperaturtoppene i bygget. Dette er fordi tidspunktene der kjølemaskin ikke har kapasitet til å produsere nok kjøling kan lagret fungere som en buffer. Av samme grunn kan et kjølesystem bestående av lager og kjølemaskin kan kjølemaskinen neddimensjoneres. Denne optimaliseringen av driften til kjølemaskinen kan redusere investeringskostnadene og sørge for mindre slitasje av kjølemaskinen.

For å benytte prognose og optimalisere driften av kjølesystemet er det imidlertid avgjørende at prognosene har høy treffsikkerhet. Prognose av værforhold er viktig for prediksjon av kjøle behovet, særlig værparametrene utetemperatur og solinnstråling. Basert på metrologiske institutt sine rapporter ser det ut til at det er mulig å predikere utetemperatur med relativt høy treffsikkerhet, eksempelvis for utetemperatur ligger gjennomsnittlig MAE på 1,5 grader celsius gjennom året. Samtidig er det noe lavere treffsikkerhet for global solinnstråling, der særlig sommerperiodene gir lavere treffsikkerhet.

Bruk av energipris i prognose kan også gi gevinster i form av reduserte energikostnader. Kjøle produksjonen kan reguleres etter når fremtidig energipris er lav eller høy. Korttidsprognose av kraftprisen er 100 prosent treffsikker. I fremtiden kan det også bli kostnadseffektivt å benytte prognoser av effekttariff. Dette fordi nye strømmålerne med timesoppløsning vil muliggjøre timesdifferensierte effekttariffer. Selv om energiprisen kan gi indikasjoner på når det er økonomisk gunstig å produsere er det også viktig å ta hensyn til ytelsen til maskinen i gjennom

døgnet. Selvom energiprisen er lav på ett tidspunkt kan dette tidspunktet være ugunstig med tanke på anleggets optimale kjølefaktor.

I dag benyttes ulike reguleringsmetoder for kjøling som regulerer etter nåtidsmålte verdier. En av de mindre effektive regulerings- og styringsteknikkene er AV/PÅ-styring (intermittent), som kan sørge for slitasje av kompressorer og energisløsing i form av unøyaktig regulering. Få bygninger benytter seg av prognose i reguleringen. Ett unntaket er REMA 1000 lageret som operasjonelt benytter seg av prognoser i sin daglige drift av sitt energisystem. I tillegg er det utført en del studier med prognose modellregulering av kjølesystemer. Disse viser til energibesparelser for kjøling mellom 17-40 prosent reduksjon. Fordelen med prognose modellregulering er at det er mulig å benytte seg av flere prognoser og optimalisere viktigheten til de ulike prognoseparameterne, eksempelvis strømpris, kjølefaktor og utetemperatur. Sammen med prognosene modelleres og benyttes modeller for kjølesystemet og bygget for å beskrive varmebalansen til bygget frem i tid.

På en annen side, kan slik MPC føre til større kompleksitet og krav til kompetanse til de som overvåker kjølesystemet. For den som overvåker kan det kanskje bli vanskelig å se årsakvirkningssammenheng hvis det oppstår avvik i reguleringen. Samtidig kan kompleksiteten kreve høy simuleringstid og datakapasitet. Dette vil igjen kreve investeringskostnader i datamaskin/server og i digitale plattformer som må samarbeide for effektiv regulering.

Diskusjon av simuleringsresultater for prognosemodeller og MPC

Analyse av modeller for prediksjon av innnetemperatur viser at de tre nevrale nettverkene oppnår høyere treffsikkerhet enn det termiske nettverket. Den tradisjonelle metoden med termisk nettverk ser imidlertid ut til å ha bedre treffsikkerhet for lavere treningsperioder og derav mindre mengde input. Likevel er det viktig å merke seg at treffsikkerheten kanskje ville vært høyere om det termiske nettverket var mindre forenklet. Eksempelvis ved andre ordens differensial likning med flere resistanser og kapasitanser. Varmebalansen til bygningskroppen er ofte kompleks og mer avansert termisk nettverk ville kanskje bedre klart å modellere den faktiske bygningskroppen.

Uavhengig av detaljnivået til det termiske nettverket har de to nevrale nettverkene en konkurransemessig fordel. Dette er vekten og følgingen av verdiene tilhørende foregående tidssteg. De nevrale nettverkene lærer seg neste verdi i stor grad basert på forrige times verdi. Dette gjør at neste timesverdi blir lettere å predikere.

Fra sammenligningen av de fire nettverkene ser det ut til at de tre nevrale nettverkene har lav NRMSE for kortere treningsperioder. For treningsperiode på 30 dager oppnår de nevrale nettverkene NRMSE på ca 0.5, hvilket er relativt sett er mye høyere det termiske nettverket med 0.28 med treningsperiode på fem dager. Derav krever de nevrale nettverkene lengre treningsperioder for å oppnå høy treffsikkerhet.

Videre ble FN og NX sammenlignet for lengre treningsperioder med prediksjon av innnetemperatur og kjølebehov. Forskjellen mellom det NX og FN er hovedsakelig tilbakekoblingen. Imidlertid ble ikke denne benyttet i treningsperioden. Fra simuleringsresultatene ligger de tett i NRMSE, men det ser ut at FN å oppnår høyest treffsikkerhet for både kjølebehov og innnetemperatur. I den anledning er det aktuelt å stille seg kritisk til hvilke faktorer som gjør at det ene

nettverket presterer bedre enn det andre. Det kan være at det ene er bedre tilpasset (“fitted”) til input og output enn det andre på grunn av de to ulike matlab funksjonene. Det kan også være at det ene nettverket rett og slett er bedre trent.

Fra analyse av FN-prediksjon av kjølebehov og innetemperatur for dag med høy solinnstråling kommer det frem at treffsikkerheten til nettverket er noe lavere sammenlignet med en “gjennomsnittlig dag”. Særlig har kjølebehovet høyere treffsikkerhet enn innetemperatur. Årsaken til dette kan være relatert til inputen som er gitt nettverket, i tilfellet variasjonene i kjølebehov er større kan det være lettere å oppnå høyere treffsikkerhet, selv med normalisering av input og output.

Med forenklet MPC av kjølebehov viser det seg at prediksjonen av kjølebehov på en “gjennomsnittlig dag” er mer treffsikker enn på en “dag med maksimalt kjølebehov”. Over prognosehorisonten på 15 timer i løpet av en “gjennomsnittlig dag” er det maksimale avviket mellom målverdi og MPC i kjølebehov ca 200 wh/h. Mens for “dag med maksimalt kjølebehov” ligger prediksjonen godt under målverdi. Dette kan tyde på at systemmodellens treffsikkerhet er lavere for avvikstilstander som høy solinnstråling og dagen med maksimalt kjølebehov. På en annen side kan det også være på grunn av treningsperioden over ett år. Om nettverket var trent på sommerhalvåret kunne treffsikkerheten til prediksjonen på dagene med avvikstilstander økt.

Diskusjon av antakelsene tatt for simulering

Basert på simuleringsresultatene er treffsikkerheten til MPC-en veldig høy. I den anledning er det viktig å ta hensyn til hvilke antakelser som har blitt tatt i analysen.

Blant dem er antakelse om 100 prosent treffsikker værprognose, noe som ikke er tilfellet i virkeligheten. Fra litteraturstudiet ble det vist at treffsikkerheten varierte avhengig av værparameter. Utetemperatur hadde relativt sett høyere treffsikkerhet enn global solinnstråling. Dermed kan man påstå at antakelsen er tilnærmet korrekt for utetemperatur mens noe mer feilaktig for solinnstråling.

Videre i analyse av et standardisert kontorbygg ble to soner analysert, sørvendt og nordvendt kontorcelle. Sørvendt kontorcelle ble valgt. Dette var på grunn av høyest maksimalt effektbehov(kWh/h) til kjøling. Øvre grense for kjølebehov lå tilnærmet 400 Wh/h høyere for sørvendt sone enn for nordvendt. Denne antakelsen gjør at ikke all informasjon om bygningskroppen analyseres. Eksempelvis vil ikke transport av luft mellom sonene eller soner av annen størrelse en kontorcelle bli sett på. Motargumentet er imidlertid at selv om ikke all informasjon blir analysert blir relevant del av bygningskroppen analysert. Sørvendt kontorcelle er “worst-case” scenarioet fra IDA ICE modellen, den sonen med maksimal kjølebehov, lavest areal og høyest solinnstråling(mot sør).

Tredje antakelse er bruken av IDA ICE modellen som ett virtuelt eksperiment. Dette betyr at IDA ICE modellen benyttes som det eksperimentelle bygget for å teste hypotesen. Responsen til IDA ICE modellen anses derfor som realistisk respons for tilsvarende bygg i virkeligheten. Modeller vil aldri helt klare å reflektere naturens tilfeldigheter og responser. Imidlertid er IDA ICE en av få modellerings programmer med høyt detaljnivå og anses som ett godt verktøy for å simulere sannsynlig respons til en bygningskropp i virkeligheten.

Den fjerde antakelsen antar at de interne lastene reflekterer standardverdiene til SN/TS 3031.

Disse internlastene reflekterer et “standardisert” kontorbygg, hvorvidt en kontorcelle vil ha samme internlast profil er variabelt. Internlasten vil være avhengig av adferden til brukeren av rommet, automatisering av elektriske installasjoner og lys.

Avslutningsvis har det blitt antatt at midlere effekt per time for kjølebehov til svarer maksimal effekt for kjøling. Denne antakelsen er tatt ettersom det blir sett på prognose frem i tid og det er ønskelig å se på hvor mye energi som kan trengs produseres i løpet av en time og reguleringshorisonten er definert som en time.

Konklusjon

Innenfor rammen til denne oppgaven er det grunnlag for å konkludere med:

- Lagring av energi til kjøling gir gode muligheter for utnyttelse av prognose. Lagret energi gir mulighet til bruk av energi ved et senere tidspunkt. Ved bruk av MPC kan tidspunktet for lagring optimaliseres med hensyn på både eksempelvis vær, energipris og kjøleytelse. Bruk av lager for energi gjør det mulig å neddimensjonere kjølemaskin. Dette reduserer investeringskostnader. Samtidig vil mulighet for å jevne ut temperaturstigninger øke når det er tilgjengelig lagret energi til kjøling. Prediksjon av kjølebehov gir muligheten til å forutsi hvor stor mengde energi som må lagres for å dekke fremtidig behov.
- Svart-boks modellering med nevralt nettverk sammenlignet med termisk nettverk for systemmodeller til prediksjon oppnår høyest treffsikkerhet når det er tilgang på store mengder historisk måledata, inntil ett år. I tilfellet det er mangel på historisk måledata kan gråboks modellen, termiske nettverk, ha høyere presisjon. Prediksjon på dager med høyere kjølebehov vil ha lavere treffsikkerhet enn på dager med lavere kjølebehov. Størrelsen på kjølebehovet avhenger av økning i solinnstråling, utetemperatur og internelaster.
- MPC for kjølebehov gjør det mulig å predikere kjølebehovet med relativt høy treffsikkerhet. Evaluering av hvordan MPC-reguleringen vil påvirke energibruken til kjøling er nødvendig å ta med i videre arbeid. Imidlertid, basert på litteraturstudiet skal MPC av kjølesystem kunne gi energibesparelser mellom 17-40 prosent.

Videre arbeid

I løpet av denne oppgaven er det flere interessante faktorer som kan videreutvikles:

- Bestemme kjølesystem og modellere det i matlab og IDA ICE. Analysere energiforbruk til kjøling istedenfor kjølebehov. Eventuelt bruke settpunkt til isvannstemperatur som reguleringsparameter.
- Teste MPC på virtuell bygningsmiljø i Matlab. Sammenligne tradisjonell reguleringsteknikk med MPC. I tilfellet det er mulig i fremtiden å samkjøre matlab og IDA ICE; teste MPC i IDA ICE. Ennå mer interessant hadde vært å teste MPC for kjølesystemet i virkeligheten for ett kontorbygg eller kontorcelle.
- Teste MPC med usikkerhet i værprognose. Se hvor godt reguleringshorisonten korrigerer for usikkerheten.
- Videreutvikle MPC til å minimere energikostnader ved bruk av eksempelvis kjølefaktor i løpet av døgnet, fremtidig effekttariff og kraftpris.

Bibliografi

- AB, E.S., 2019. IDA Indoor Climate and Energy. URL: <https://www.equa.se/en/ida-ice>.
- Afram, A., Farrokh, J.S., 2014. Theory and applications of HVAC control systems - A review of model predictive control (MPC). *Building and Environment* 72, 343–355. doi:10.1016/j.buildenv.2013.11.016.
- Arbeidstilsynets veiledning 444, 2012. Klima og luftkvalitet på arbeidsplassen. 444 .
- Arya, J.S., Chavda, N.K., 2014. Design and Performance Analysis of Water Chiller-A Research. *Journal of Engineering Research and Applications* www.ijera.com 4, 19–25. URL: www.ijera.com.
- Behrooz, F., Mariun, N., Marhaban, M.H., Radzi, M.A.M., Ramli, A.R., 2018. Review of control techniques for HVAC systems-nonlinearity approaches based on fuzzy cognitive maps. *Energies* 11. doi:10.3390/en11030495.
- Burant, J., 2017. Fast Model Predictive Control with Long Prediction Horizon. Thesis URL: https://dspace.cvut.cz/bitstream/handle/10467/68600/F3-DP-2017-Burant-Jiri-Fast_Model_Predictive_Control_with_Long_Prediction_Horizon.pdf.
- Byggforskserien, 2010. 552.350 Systemer for vannbåret kjøling for næringsbygg med store varmetilskudd. Technical Report. URL: https://www.byggforsk.no/dokument/538/systemer_for_vannbaaret_kjoeling_for_naeringsbygg_med_store_varmetilskudd#i5.
- Byggkvalitet, D.f., 2017. Byggteknisk forskrift (TEK17). URL: <https://dibk.no/byggereglene/byggteknisk-forskrift-tek17/14/14-2/>.
- Catano, J., Zhang, T., Wen, J.T., Jensen, M.K., Peles, Y., 2013. Vapor compression refrigeration cycle for electronics cooling - Part I: Dynamic modeling and experimental validation. *International Journal of Heat and Mass Transfer* 66, 911–921. URL: <http://dx.doi.org/10.1016/j.ijheatmasstransfer.2013.06.075>, doi:10.1016/j.ijheatmasstransfer.2013.06.075.
- Causone, F., Corgnati, S.P., Filippi, M., Olesen, B.W., 2010. Solar radiation and cooling load calculation for radiant systems: Definition and evaluation of the Direct Solar Load. *Energy and Buildings* 42, 305–314. doi:10.1016/j.enbuild.2009.09.008.

-
- Chai, T., Draxler, R.R., 2014. Root mean square error (RMSE) or mean absolute error (MAE)? -Arguments against avoiding RMSE in the literature. *Geoscientific Model Development* 7, 1247–1250. doi:10.5194/gmd-7-1247-2014.
- Clauß, J., Stinner, S., Sartori, I., Georges, L., 2019. Predictive rule-based control to activate the energy flexibility of Norwegian residential buildings: Case of an air-source heat pump and direct electric heating. *Applied Energy* 237, 500–518. URL: <https://doi.org/10.1016/j.apenergy.2018.12.074>, doi:10.1016/j.apenergy.2018.12.074.
- Dokka, M.T.A.G.L.T., 2013. Kartlegging av mekanisk kjøling i nye kontor- og forretningsbygg. Technical Report.
- Dokka, T.H., Kristjansdottir, T.F., Time, B., Mellegård, S.E., Haase, M., Tønnesen, J., 2013. A zero emission concept analysis of an office building, ZEB Project report no 8. URL: <https://brage.bibsys.no/xmlui/handle/11250/2387621>.
- Dong, B., Lam, K.P., 2014. A real-time model predictive control for building heating and cooling systems based on the occupancy behavior pattern detection and local weather forecasting. *Building Simulation* 7, 89–106. doi:10.1007/s12273-013-0142-7.
- Eini, R., Abdelwahed, S., 2019. Learning-based Model Predictive Control for Smart Building Thermal Management URL: <http://arxiv.org/abs/1909.05331>.
- Energidepartementet, O.o., 2019. Forskrift om økonomisk og teknisk rapportering, inntektsramme for nettvirksomheten og tariffer. URL: https://lovdata.no/dokument/SF/forskrift/1999-03-11-302#KAPITTEL_5.
- Fatima Amara¹, Kodjo Agbossou, A.C.Y.D.S.K., 2015. Comparison and Simulation of Building Thermal Models for Effective Energy Management. *Smart Grid and Renewable Energy*, 2015, doi:10.1039/c5tb02377g.
- Gergely Marton, 2019. MIP for demand side optimisation Gergely Marton. Master Thesis, UNIVERSIDAD DE OVIEDO , 130.
- Hammer, L., 2019. Regelbasert prognosestyring for å minimere energibruk og effektforbruk for romkjøling i norske kontorbygg. Technical Report.
- Hansen, H., Jonassen, T., Mook, V., 2017. Forslag til endring i forskrift om kontroll av nettvirksomhet: Utforming av uttakstariffer i distribusjonsnettet. URL: <http://webfileservice.nve.no/API/PublishedFiles/Download/201706767/2242754>.
- Homleid, M., Tveter, F.T., Jan, P., Haugen, E., 2016. METinfo Verification of Operational Weather Prediction Models September to November 2016 URL: https://www.met.no/publikasjoner/met-info/met...2016/_/.../MET-info-22-2016.pdf%0A.
- Homod, R.Z., 2013. Review on the HVAC System Modeling Types and the Shortcomings of Their Application. *Journal of Energy* 2013, 1–10. doi:10.1155/2013/768632.
- Institutt, M., 2019. Gratis tilgang til Meteorologisk institutts vær- og klimadata fra historiske data til sanntidsobservasjoner. URL: <http://eklima.met.no>.
-


-
- Joe, J., Karava, P., 2019. A model predictive control strategy to optimize the performance of radiant floor heating and cooling systems in office buildings. *Applied Energy* 245, 65–77. doi:10.1016/j.apenergy.2019.03.209.
- Johannessen, J.E., 2018. Høring om forslag til endringer i forskrift om kontroll av nettvirkosheten – tariffer 2 Bakgrunnen for innføring av nye tariffer Innføringen av AMS , 1–11.
- Jonsson, K.B., 2014. Bruk av værprognoser for optimal styring av snøsmelteanlegg .
- Kristiansen, J., Bakketun, , 2018. StråInn .
- Kumar, R., Aggarwal, R.K., Sharma, J.D., 2013. Energy analysis of a building using artificial neural network: A review. *Energy and Buildings* 65, 352–358. URL: <http://dx.doi.org/10.1016/j.enbuild.2013.06.007>, doi:10.1016/j.enbuild.2013.06.007.
- Langseth, B., 2016. Analyse av energibruk i yrkesbygg. URL: http://publikasjoner.nve.no/rapport/2016/rapport2016_24.pdf.
- Lønsethagen, H., 2019. Bruk av nevralt nettverk med minne for forbedring av sanntids lokasjonssystemer .
- Ma, Y., Kelman, A., Daly, A., Borrelli, F., 2012. Predictive control for energy efficient buildings with thermal storage: Modeling, stimulation, and experiments. *IEEE Control Systems* 32, 44–64. doi:10.1109/MCS.2011.2172532.
- Marnk, K., Rojicek, J., Stluka, P., Vass, J., 2011. Advanced HVAC control: Theory vs. reality. *IFAC Proceedings Volumes (IFAC-PapersOnline)* 44, 3108–3113. doi:10.3182/20110828-6-IT-1002.03085.
- Matlab R2019b, . goodnessOfFit. URL: <https://se.mathworks.com/help/ident/ref/goodnessoffit.html>.
- Matlab R2019b, 2019a. immse. URL: <https://se.mathworks.com/help/images/ref/immse.html>.
- Matlab R2019b, 2019b. Multilayer Shallow Neural Network Architecture. URL: <https://se.mathworks.com/help/deeplearning/ug/multilayer-neural-network-architecture.html>.
- Meteorologiske institutt;, 2019a. Norwegian Meteorological Institute from historical data to real time observations URL: eklima.met.no.
- Meteorologiske institutt;, 2019b. Welcome to the MET Norway Weather API v.3. URL: <https://api.met.no/>.
- Miljødepartementet, K.o., 2019. Norge foreslår avtale om klimasamarbeid med EU. URL: <https://www.regjeringen.no/no/aktuelt/klimasamarbeid-med-eu/id2632883/>.
- Næs, T., Kvaal, K., Isaksson, T., Miller, C., 1993. Artificial Neural Networks in Multivariate Calibration. *Journal of Near Infrared Spectroscopy* 1, 1–11. doi:10.1255/jnirs.1.

-
- NordPol, C.S., 2019. Day-ahead market. URL: <https://www.nordpoolgroup.com/the-power-market/Day-ahead-market/>.
- Olje- og Energidepartementet;, 1999. Forskrift om økonomisk og teknisk rapportering, inntektsramme for nettvirksomheten og tariffer. URL: https://lovdata.no/dokument/SF/forskrift/1999-03-11-302#KAPITTEL_5.
- Opalic, S., 2019. Kommunikasjon med Sven Opalic .
- Pang, X., Duarte, C., Haves, P., Chuang, F., 2018. Testing and demonstration of model predictive control applied to a radiant slab cooling system in a building test facility. *Energy and Buildings* 172, 432–441. URL: <https://doi.org/10.1016/j.enbuild.2018.05.013>, doi:10.1016/j.enbuild.2018.05.013.
- Sarbu, I., Sebarchievici, C., 2018. A comprehensive review of thermal energy storage. *Sustainability (Switzerland)* 10. doi:10.3390/su10010191.
- Seierstad, I.A., 2019. Kommunikasjon med Seierstad.
- Sharma, K., 2017. Automation Strategies. Overview of Industrial Process Automation , 53–74URL: <https://linkinghub.elsevier.com/retrieve/pii/B9780128053546000062>, doi:10.1016/B978-0-12-805354-6.00006-2.
- Spilde, D., Lien, S.K., Ericson, T.B., Magnussen, I.H., 2018. Energibruk i Norge mot 2035 URL: http://publikasjoner.nve.no/rapport/2018/rapport2018_43.pdf.
- Standard-Norge, 2016. SN/TS 3031:2016 for beregning av energibehov og energiforsyning .
- Sun, D.W., 2011. Handbook of Frozen Food Processing and Packaging.
- THEMA Consulting Group, 2013. Energibruk i kontorbygg , 90.
- Thue, J.V., 2016. Bygningsfysikk Grunnlag. 1 ed., Fagbokforlaget, Trondheim.
- Trond Andresen, Bjørne A.Foss, J.G., 2016. Reguleringsteknikk. 6 ed., Institutt for teknisk kybernetikk, Trondheim.
- Wang, Z., Ding, Y., Deng, H., Yang, F., Zhu, N., 2018. An occupant-oriented calculation method of building interior cooling load design. *Sustainability (Switzerland)* 10, 1–29. doi:10.3390/su10061821.
- Wittchen, K.B., Løgberg, E., Pedersen, S., Djurtoft, R., Thiesen, J., 2005. USE OF WEATHER FORECASTS TO CONTROL NIGHT COOLING Danish Building Research Institute , Hørsholm , Denmark Birch & Krogboe A / S , Consultants and Planners , Virum , Denmark Vejr2 – Private Weather-service of Denmark , Roskilde , Denmark. 9th International IBPSA Conference , 1347–1354.
- yr.no, 2019. Slik lager vi værvarslene på Yr. URL: <https://hjelp.yr.no/hc/no/articles/360004008874-Slik-lager-vi-v\OT1\aevarslene-p\unhbox\voidb@x\bgroup\let\unhbox\voidb@x\setbox\@tempboxa\hbox{\a\global\mathchardef\accent@spacefactor\spacefactor}\accent23a\egroup\spacefactor\accent@spacefactor-Yr>.
-


Yu, F.W., Chan, K.T., 2008. Optimization of water-cooled chiller system with load-based speed control. *Applied Energy* 85, 931–950. doi:10.1016/j.apenergy.2008.02.008.

Appendiks

9.1 Plantegninger




Figur 9.1: Plantegning 1-3 etg. ZEB rapport.




Figur 9.2: Plantegning 4 etg. ZEB rapport.


9.2 Fasadetegninger



Figur 9.3: Fasade nord ZEB rapport.



Figur 9.4: Fasade sør ZEB rapport.



Figur 9.5: Fasade vest ZEB rapport.



Figur 9.6: Fasade øst ZEB rapport.

9.3 Matlab koder

Disse gir kodene brukt for modellene. De har blitt modifisert i løpet av oppgaven avhengig av tilfellet. Dette er imidlertid beskrevet til oppgaven.

9.3.1 Tilbakevendende nettverk - NX

```
1 clear all
2 %Innhenter verdier for input og output
3 input=transpose(readmatrix("Input—heleaaret.xlsx"));
4 outputs=transpose(readmatrix("Output—heleaaret.xlsx"));
5 %Normaliserer outputen ettersom vi har to med forskjellig skala
6 %Bruker z-verdi for normalisering, standardavvik, gjennomsnitt
   beregnes
7 stdTemp=std2(outputs(1,:));
8 meanTemp=mean(outputs(1,:));
9 stdCool=std2(outputs(2,:));
10 meanCool=mean(outputs(2,:));
11 zTemp=zscore(outputs(1,:));
12 zCool=zscore(outputs(2,:));
13 %Kjoerer for-loekke for beregning output
14 output=size(outputs);
15 for i=1:output(2)
16 output(1,i)=zTemp(i);
17 output(2,i)=zCool(i);
18 end
19 %Konverterer numerisk vektor til sekvensiell
20 input=con2seq(input);
21 output=con2seq(output);
22 %Definerer input- og tilbakekoblingsforsinkelse
23 d1 = [1:2];
24 d2 = [1:2];
25 %Definerer nettverk med skjulte lag med antall nevroner [8 8],
   to skjulte og 8 nevroner
26 %i hvert lag
27 narx_net = narxnet(d1,d2,[8 8]);
28 %Setter minsteverdi for treningsparameter
29 narx_net.trainParam.min_grad = 1e-10;
30 %Forbrede input og maalverdi for simulering og trening
31 [p,Pi,Ai,t] = preparets(narx_net,input,{},output);
32 %Bayesian framework treningsalgoritme
33 narx_net = trainbr(narx_net,p,t,Pi);
34 %Simulerer nettverk
35 yn = sim(narx_net,p,Pi);
36 %Gjoer om sekvensiell output til numerisk
37 yn=(cell2mat(yn));
```

```

38 %Gjoer om sekvensiell m lverdier til numerisk
39 t=cell2mat(t);
40 %Denormaliserer output
41 y=size(t);
42 for i=1:8757
43     y(1,i)=yn(1,i)*stdTemp+meanTemp;
44     y(2,i)=yn(2,i)*stdCool+meanCool;
45 end
46 %Sjekker treffsikkerhet med NRMSE
47 cost_func = 'NRMSE';
48 %Bruker GoodnessofFit for se paa NRMSE for simulert og
    maalverdi
49 fit = goodnessOfFit(transpose(yn),transpose(t),cost_func);
50 %Lukker nettverket slik at det kan brukes med lukket sloyfe og
    tester for treningsperiode
51 netc = closeloop(narx_net);
52 %Forbrede input og maalverdi for simulering og trening
53 %Velge for perioden (:) avhengig av hva vi ser p
54 [p1,Pi1,Ai1,t1] = preparets(netc,input(:),{ },output(:)t);
55 %Simulere nettverk
56 yn = netc(p1,Pi1,Ai1);
57 %Konverterer sekvensiell til numerisk
58 yn=(cell2mat(yn));
59 t1=cell2mat(t1);
60 %Denormaliserer output
61 y=size(t1);
62 for i=1:8757
63     y(1,i)=yn(1,i)*stdTemp+meanTemp;
64     y(2,i)=yn(2,i)*stdCool+meanCool;
65 end
66 %Tester treffsikkerhet, NRMSE med tilbakekopling
67 cost_func = 'NRMSE';
68 fit2 = goodnessOfFit(transpose(yn),transpose(t1),cost_func);

```

9.3.2 Flerlagsforover nettverk - FN

```

1 clear all
2 %Henter input og output
3 input=transpose(readmatrix("Input—heleaaret.xlsx"));
4 outputs=transpose(readmatrix("Output—heleaaret.xlsx"));
5 %Normaliserer outputen ettersom vi har to med forskjellig skala
6 %Bruker z-verdi for normalisering, standardavvik, gjennomsnitt
    beregnes
7 stdTemp=std2(outputs(1,:));
8 meanTemp=mean(outputs(1,:));
9 stdCool=std2(outputs(2,:));

```

```

10 meanCool=mean(outputs(2,:));
11 zTemp=zscore(outputs(1,:));
12 zCool=zscore(outputs(2,:));
13 %Kjoerer for-loekke for beregning output
14 output=size(outputs);
15 for i=1:output(2)
16 output(1,i)=zTemp(i);
17 output(2,i)=zCool(i);
18 end
19 %Bayesian framework treningsalgoritme
20 trainFcn = 'trainbr';
21 %Definerer flerlagsforovernettverk med 50 og 40 nevroner
22 net = feedforwardnet([50 40], trainFcn);
23 %Definerer aktiveringsfunksjoner for hvert lag
24 %Aktiveringsfunksjon for laget Sigmoid
25 net.layers{1}.transferFcn = 'tansig';
26 %Aktiveringsfunksjon for laget Sigmoid
27 net.layers{2}.transferFcn = 'tansig';
28 %Aktiveringsfunksjon for laget lineear
29 net.layers{3}.transferFcn = 'purelin';
30 %Valideringfeil nummer maksimum
31 net.trainParam.max_fail = 6;
32 %Antall maks epoker
33 net.trainParam.epochs=1000;
34 %Learingsrate
35 net.trainParam.lr = 1;
36 %Maal for simulering – null error
37 net.trainParam.goal = 0;
38 %Reguleringsparameter
39 net.performParam.regularization = 0.001;
40 %Initiere nettverket
41 net = init(net);
42 %Trene nettverket med input og output
43 [net, tr] = train(net, input, output);
44 %Simulere nettverk
45 yn = net(input);
46 %Denormalisere nettverk
47 y=size(outputs);
48 for i=1:length(zTemp)
49     y(1,i)=yn(1,i)*stdTemp+meanTemp;
50     y(2,i)=yn(2,i)*stdCool+meanCool;
51 end
52 out = outputs;
53 %Definerer avviksfunksjon NRMSE
54 cost_func = 'NRMSE';
55 %Beregner fit
56 fit = goodnessOfFit(transpose(y), transpose(out), cost_func);

```

9.3.3 Lag-tilbakevendende nettverk - LRN

```
1 clear all
2 %innhenter verdier for input og output
3 input=transpose(readmatrix("Input-heleaaret.xlsx"));
4 outputs=transpose(readmatrix("Output-heleaaret.xlsx"));
5 %Normaliserer outputen ettersom vi har to med forskjellig skala
6 %Bruker z-verdi for normalisering, standardavvik, gjennomsnitt
   beregnes
7 stdTemp=std2(outputs(1,:));
8 meanTemp=mean(outputs(1,:));
9 stdCool=std2(outputs(2,:));
10 meanCool=mean(outputs(2,:));
11 zTemp=zscore(outputs(1,:));
12 zCool=zscore(outputs(2,:));
13 %Kjører for-løkke for beregning output
14 output=size(outputs);
15 for i=1:output(2)
16     output(1,i)=zTemp(i);
17     output(2,i)=zCool(i);
18 end
19 %Konverterer numerisk vektor til sekvensiell
20 input=con2seq(input);
21 output=con2seq(output);
22 net = layrecnet(1:2,[10,10]);
23 %Forbrede input og maalverdi for simulering og trening
24 [Xs,Xi,Ai,Ts] = preparets(net,input,output);
25 %Definerer maks antall epoker
26 net.trainParam.epochs=20;
27 %Trener nettverket
28 net = train(net,Xs,Ts,Xi,Ai);
29 %Se p nettverk
30 view(net)
31 %Simulerer over treningsperiode
32 Yn = net(Xs,Xi,Ai);
33 %Gjør om sekvensiell output til numerisk
34 Yn=(cell2mat(Yn));
35 %Gjør om sekvensiell output til numerisk
36 Ts=cell2mat(Ts);
37 %Denormaliserer output
38 Y=size(Ts);
39 for i=1:8757
40     Y(1,i)=Yn(1,i)*stdTemp+meanTemp;
41     Y(2,i)=Yn(2,i)*stdCool+meanCool;
42 end
43 %Bruker GoodnessofFit for se p NRMSE for simulert og
   m lverdi
```

```

44 cost_func = 'NRMSE';
45 fit = goodnessOfFit(transpose(Yn), transpose(Ts), cost_func);

```

9.3.4 Termisk nettverk

```

1 %Definerer foerste ordens differensial likning for en sone
2 odefun = 'Thermalzone';
3 %Definerer initielle resistans og kapasitans
4 R1=0.169;%basert p U-verdi for bygningskroppen
5 C1=31440;%Basert p mengde luft i rommet, volum og
   varmekapasitet
6 parameters={'R1', R1; 'C1', C1};
7 %Definerer funksjonstype. F rst kontinuelig
8 fcn_type = 'c';
9 %Initierer systemet
10 init_sys = idgrey(odefun, parameters, fcn_type);
11 %Henter input=u og output=y
12 u=(readmatrix("AugustGBKelvin.xlsx"));
13 y=(readmatrix("AugustTempIKelvin.xlsx"));
14 %Lager datasett definert kontinuelig
15 data = iddata(y,u,1);
16 %Lager Graa-boks modell med initielt system og data. Estimerer
   parametere for R1 og C1
17 sys = greyest(data, init_sys);
18 %-----L sning-----
19 %Definerer Parametere basert p loesning sys
20 %Definerer modellens vektorer
21 A= -1/(R1*C1);
22 B= [1/(R1*C1), 1/(C1), 1/(C1), 1/(C1)];
23 C= 1;
24 D= [0 0 0 0];
25 K=0;
26 x0=0;
27 %Bruker idss format
28 sysi = idss(A,B,C,D,K,x0,0);
29 %Konverterer sys til diskret modell
30 sysd = c2d(sysi,3600, 'zoh');

```

9.3.5 Termisk nettverk modellen til sonen

```

1 %Foerste ordens differensiallikning for kontor soervendt
2 function [A, B, C, D] = Thermalzone(R1,C1,Ts)
3 %Definerer vektorer, A=tilstandsvektor, B=forstyrrelses vektor,
   C=output

```

```

4 %Vektor , D=nulles ,inkluderes ikke pga foerste ordens oppsett
5 A= -1/(R1*C1);
6 B= [1/(R1*C1), 1/(C1), 1/(C1), 1/(C1)];
7 C= 1;
8 D= [0 0 0 0];
9 end

```

9.3.6 Forenklet MPC til FN- Optimering

```

1 function [Tvec , Qcvec]=MPC15h(in)
2 %Definerer null-vektorer for prognose kj lebehov og
   innetemperatur
3 Tvec=zeros(1,15);
4 Qcvec=zeros(1,15);
5 %Initielle verdier
6 %in=transpose(input(1:7,5089)); Hente i command eventuelt.
7 %MPC reguleringssslyfe med objektiv funksjon
8 for i=1:15
9     [T, Qc]=Usenetwork(in);
10    %objektiv funksjon som bruker simulerte resultater for
       modellen
11    %f satt lik en for utput
12    f=[1 1];
13    %Ingen mindre eller er lik betingelser
14    A=[0 0; 0 0];
15    b=[0 0];
16    %Bruker system dynamikk fra kontorcelle nevralt nett til
       definere
17    %tilstandsvariablene objektive funksjonen
18    Aeq=[1 0;0 1];
19    beq=[T Qc];
20
21    %vre og nedre grenser: krever at innetemperaturen det er
       kj lebehov bare tilfellet
22    %innetemperaturen er over 24 grader
23    lb=[23.9,0];
24    ub=[1000, 1200];
25
26    %L ser objektfunksjon med alle begrensninger
27    x=linprog(f, A, b, Aeq, beq, lb, ub);
28
29    %Bruker l sning videre for neste prognose for neste time
30    Qcvec(i)=x(2);
31    Tvec(i)=x(1);
32    %Henter v rprognose fra yr
33    input=transpose(readmatrix("Input-heleaaret.xlsx"));

```

```
34     inweather=transpose(input(1:5,5098+i));
35     %Setter input for neste times prognose med predikert
      kj lebehov og
36     %inntemperatur for forrige time.
37     in=[inweather x(1) x(2)];
38 end
```

