



SLUTRAPPORT

AI-tillämpningar för energilagring i kulturhistoriska byggnader

Abolfazl Hayati (HiG)

Jan Akander (HiG)

Magnus Mattsson (HiG)

Ali Ghadirzadeh (RoboUbiq AB)

Hossein Bakhtiari (Gavlefastigheter AB)

Björn Karlsson (HiG)

Energimyndighetens projektnummer 2022-200334




FÖRORD

Spara och bevara är ett forsknings- och utvecklingsprogram som Energimyndigheten initierat för att öka kunskapen om energieffektivisering i kulturhistoriskt värdefulla byggnader. Programmet syftar till att utveckla och förmedla kunskap och tekniklösningar som bidrar till en energieffektivisering i dessa byggnader utan att deras värden och inventarier förstörs eller förvanskas.

Den varsamma energieffektiviseringen ska uppnås genom interdisciplinära samarbeten, där teknik möter kulturvård. Målet är att skapa en bestående kunskapsgrund inom området energieffektivisering i kulturhistoriskt värdefulla byggnader och bidra till en långsiktig, hållbar förvaltning av det äldre fastighetsbeståndet.

Programmet samordnas av Uppsala universitet.


Rapporten redovisar projektets resultat och slutsatser. Publicering innebär inte att Energimyndigheten eller Uppsala universitet tar ställning till framförda slutsatser, resultat eller eventuella åsikter.



SAMMANFATTNING

Historiska byggnader står för en betydande del av dagens byggnadsbestånds energianvändning, samtidigt som energibesparande åtgärder på dessa är begränsade av regelverk kring kulturellt bevarande, antikvariska och estetiska skäl. Den del av byggnadsbeståndet som byggts före 1945 står för cirka 20 procent av all energianvändning i Sveriges byggnadsbestånd. Syftet med denna studie är att utvärdera användningen av byggnadsstommen i en specifik historisk stenbyggnad som ett värmelager. Det innebär att termisk energi lagras i byggnaden utan att den fysiskt förändras. Genom att använda artificiell intelligens (AI) och maskininlärningsmodellering kan värmeförsörjningen styras med hjälp av väderprognoser och förväntad närvaro (binär kalenderisering) av kontorspersonalen i byggnaden. Detta möjliggör optimering av energianvändning och effektbehov samtidigt som inomhustemperaturen hålls inom komfortgränserna. Projektet strävar efter att utvärdera energilagringspotentialen för att främja effektivare energianvändning i historiska byggnader genom energisimuleringar. Den genomförda studien indikerar betydande besparingar i total och spetsenergi för den undersökta byggnaden och tyder på att metoden kan tillämpas på andra liknande fall.


Nyckelord: Fjärrvärme, Djupinläring, Artificiell intelligens (AI), Historisk byggnad, Energilagring, Termisk massa, Topplastminimering (peak shaving), Komfort



Abstract


Historical buildings account for a significant portion of today's building stock energy use, with usually limited energy-saving measures feasible due to by cultural conservation rules and preservation aspects in building regulations. The part of the building stock that was built before 1945 accounts for approximately 20 percent of all energy use in the Swedish building sector. The purpose of this study is to evaluate the use of the building structure in a specific historical stone building as a heat storage system. This involves storing thermal energy in the building's structures without physically altering them. By utilizing artificial intelligence (AI) and machine learning modeling, heat supply can be controlled using forecasts of weather and binary calendarization of occupancy. This enables optimization of energy usage and power demand while maintaining adequate indoor temperatures. The project aims to assess the energy storage potential to promote more efficient energy use in historical buildings through energy simulations. The conducted study indicates significant savings in both total and peak energy for the examined building, and suggests that the method could be applied to other similar cases.

Keywords: District heating, Deep learning, Artificial Intelligence (AI), Historical building, Thermal mass, Energy Storage, Peak shaving, Thermal comfort



INNEHÅLL

FÖRORD	2
SAMMANFATTNING	3
Abstract	4
INNEHÅLL.....	5
1. INLEDNING OCH BAKGRUND.....	6
1.1 BAKGRUND	6
1.2 SYFTE OCH MÅL	8
1.3 OMFATTNING OCH AVGRÄNSNING	8
2. GENOMFÖRANDE.....	9
3. RESULTAT.....	10
4. HUR SKA RESULTATEN KOMMA TILL ANVÄNDNING.....	12
5. DISKUSSION	16
6. SLUTSATSER.....	18
7. PUBLIKATIONSLISTA	19
8. REFERENSER	20
Bilaga A: Beräkningsproceduren och utvecklingen av AI-modellen.....	21
Prediktionsmodell	21
Generative Model (Generativ modell)	22
Optimizer (Optimerare).....	23
Piece-wise linear model (Styckvis linjär modell)	23
Bilaga B: Fortsättning av resultat	24
Byggnadsenergisignatur	27
Bilaga C: Detaljerad kostnadsanalys.....	29
Bilaga D: Graphic User Interface (GUI) till presenterade AI modellen.....	30



1. INLEDNING OCH BAKGRUND


1.1 BAKGRUND

Många av våra kulturhistoriskt värdefulla byggnader används idag som bostäder, kontorslokaler, muséer, skolor mm och behöver därför förse med komfortabel innetemperatur. Den del av byggnadsbeståndet som byggts före 1945 står för cirka 20 procent av all energianvändning i landets byggnadsbestånd. Möjligheterna att energieffektivisera kulturhistoriska byggnader är samtidigt begränsade på grund av bevaranderegler (varsamhetskrav och förvanskingsförbudet). Oftast är sådana byggnader massiva konstruktioner bestående av material med hög värmekapacitet och värmekonduktivitet, vilket medför möjligheter att lagra stora energimängder utan att väsentligt variera innetemperaturerna i tiden (Akander, 2000). Men lagringsförmågan är även beroende av byggnadens värmeförluster genom värmeledning och ventilation/luftinfiltration, vilka ofta antar höga belopp och kan uttryckas som en *förlustkoefficient*. Den termiska tidskonstanten för en byggnad uppskattas genom att dividera termiska massan med förlustkoefficienten. I regel har äldre byggnader stora tidskonstanter vilket påverkar deras respons på temperaturförändringar i uteklimatet. Det vill säga att bygganden blir som ett stort värmebatteri som kan lagra energi och frigöra den senare när det är kallare ute. Energilagringen beror på byggandens storlek och termiska massa samt förlustkoefficient, samt hur mycket innetemperaturerna tillåts fluktuera. Byggnadens tidskonstant, givet lämpligt styr- och reglersystem, ger enligt (Karlsson, 2012; Norén et al., 1999; Verbeke & Audenaert, 2018), stor potential till: 1) jämnare inomhustemperaturer i tiden, 2) minskning av värmeeffektbehovet, åtminstone kortvarigt och 3) energibesparing.

Det blir allt vanligare att energiföretag erbjuder sina kunder så kallad effektberoende energiräkning, d.v.s. ju fler och högre effekttoppar man har vid t.ex. kallare väder, desto dyrare blir samma levererad mängd energi. När mycket uppvärmning behövs samtidigt från olika kunder, skapas effekttoppar i fjärrvärmenätet, vilket gör att tillfälliga och dyra resurser behövs för att täcka behovet. Olika lösningar såsom energilagringsmetoder kan bidra till laststyrning på nätet och därtill spara stora belopp både för fjärrvärmeleverantören och för fastighetsägare. Energi- och kostnadsbesparingspotentialen är ännu större hos äldre byggnader eftersom de ofta är dåligt isolerade och har stor termisk massa. Energilagringsmetoden kan leda till sparad primärenergi och effektivare resursanvändning, och samtidigt bidra till mindre växthusgasutsläpp och bättre miljö.

Att lagra värme under perioder med lägre efterfrågan till kallare perioder fungerar som en strategi för värmeeffektshantering och hållbar energiförsörjningsplanering. Följaktligen kan värmeförsörjningen till byggnaden tillfälligt minskas under perioder med höga effektbehov, vilket möjliggör användning av lagrad termisk energi i byggnadsstommen. Hayati et al. undersökte temperaturminskningen inomhus och leveransen av värmeeffekt till en flerfamiljsbyggnad med fokus på att beräkna värmelagringskapacitet och termiska trögheten (Hayati et al., 2022). I det genomförda avklingningstestet, där energiförsörjningen ströps under 5 timmar genom att utegivaren "lurades" till att känna 15 grader högre temperatur än vad som rådde vid tillfället, var den beräknade energiförsörjningsminskningen 61% under 5 timmar, vilket resulterade i en minimal temperatursänkning inomhus på endast 0,3 °C.

Artificiell intelligens (AI) och maskininlärningsalgoritmer (ML) kan identifiera inflytelserika parametrar och variabler som påverkar energianvändningen och noggrant prediktera deras värden. Dessa modeller kan urskilja potentiella effekttoppar genom att lära sig från tidigare varierande




omständigheter. AI-lösningar använder byggnadens energi- och effektsignatur, inklusive faktorer som termisk massa, termisk komfort och väderprognoser för att förutse olika timvisa och dagliga energi- och effekttoppmönster (Calikus et al., 2019; Vandermeulen et al., 2018). Denna metod innebär att träningsmodeller för styr- och reglering används med uppmätta data, som omfattar energianvändning, temperaturer och implicit värme från internlaster samt solinstrålning. Modellerna förutspår värmeförsörjning och bibehåller "flytande" inomhustemperaturer inom ett angivet intervall genom att använda den termiska massan som finns inom byggnadsskalet. Utbytet av större energimängder sker när temperaturskillnaden mellan inomhus- och utomhusmiljön ökar. Det är viktigt att förhindra överdrivna temperaturfluktuationer som kan leda till ogynnsamma relativa fuktighetsnivåer eller höga fluktuationer, vilket negativt påverkar material, inredning, föremål eller dekorationer inom byggnaden.

Att implementera intelligent drift och underhåll hos historiska byggnader innebär integrering av digitala teknologier och dataanalysmetoder. Detta tillvägagångssätt hjälper till att upprätthålla funktionerna hos dessa byggnader samtidigt som deras kulturvärden bevaras. Ni et al. utvecklade och testade en omfattande digitaliseringsplattform för intelligent underhåll av historiska byggnader (Ni, 2023). DPlattformen sammanbinder Internet of Things (IoT), molnlagring och -beräkningar samt maskininlärning med syfte att samla in data från kulturhistoriska byggnader, avslöja inomhusmiljöernas och energiprestandas status, och via en offentlig molnplattform lagra data och distribuera information och beslutsunderlag (Ni et al., 2022a, 2022b). Dessutom används djupinlärningsmodeller för att fånga trender och osäkerheter i byggnaders energianvändning (Ni et al., 2023, 2024). Plattformen kan emellertid främst användas för att övervaka byggnaden men optimerar inte den levererade energin och byggnadens energianvändning.

Att upprätthålla en delikat balans mellan att bevara autenticiteten hos kulturarvsbyggnader och att införliva energieffektivitetsåtgärder är viktigt. Genom att samordna modern teknik med engagemang för att bevara det förflutna kan vi garantera att kulturhistoriska byggnader och miljöer består som symboler för vårt kulturarv, samtidigt som de spelar en roll för att främja en mer hållbar framtid. Detta projekt syftar till att nyttja byggnadens stomme som ett värmelager för att bevara och spara energi utan fysiska ingrepp. Genom att använda AI och ML-modeller regleras värmeförsörjningen strategiskt baserat på väderprognoser och en binär kalender för personnärvaro. Denna metod möjliggör optimering av energianvändning och effektbehov samtidigt som inomhustemperaturer bibehålls inom lämpliga nivåer. Detta inkluderar tillfällig minskning av uppvärmningen utan att kompromissa med lokalernas termiska komfort.

Projektet har som utgångspunkt den mätdata som tidigare uppmäts och sparats för den studerade byggnaden, vilken medger analys av den information som dataserierna implicit innehåller. Olika ML-metoder kan användas för att prognosticera effekttoppar (med hjälp av övervakad (supervised) inlärning), identifiera mönster för prognostisering av effekttoppar, analysera optimalt energiutbyte och lagringsmetoder samt erbjuda schema för energidistributionen. Det finns också så kallade förstärkta inlärningsmodeller (Reinforcement learning) som kan lära sig av datahistorik (modell-baserad LR) och använda modellen för att träna den i beslutfattande riktlinjer/policyer som kan avgöra lämpliga åtgärder såsom schema och typ av värmetillförsel till byggnaden. Modellerna lär sig från offline eller urkopplat data (offline RL) och korregerar sig själva via provning med on-line data (trial & error) och förbättrar sin beslutsprocess genom en belöningsstruktur (till exempel, när den lyckats med minskning av toppeffekter med bibehållen termisk komfort hos brukarna), under handledning av energiexperter. På så sätt lär sig modellerna om systemets behov och variationer enligt byggnadens efterfrågan, upptäcker och prognostiserar effekttoppar och optimerar därmed energianvändning och sänker därmed uppvärmningskostnader och CO₂-utsläpp.



1.2 SYFTE OCH MÅL

Projektet bidrar till effektiv energianvändning, resursutnyttjande, flexibilitet, och robusthet och minskning av växthusgasutsläppen utan att påverka byggnaders kulturvärden, vilket är i linje med regeringens mål, bl.a. att ha 50 procent effektivare energianvändning t.o.m. år 2030 (jämfört med 2005), och även globala klimatmål såsom Parisavtalet, att hålla den globala uppvärmningen under 1,5 grader. Projektet bidrar också till Sveriges miljömål om God bebyggd miljö, Begränsad klimatpåverkan och Generationsmålet.

Syftet är att med hjälp av de förslagna AI och ML-modellerna pröva strategier för inlärning av byggnadens behov (energi och effekt) som upptäcker mönster och predikterar effekttoppar och optimerar därmed energianvändningen i god tid utan att termiska komforten inomhus försämrats.

Dessa delar ingår som projektets resultat och uppfyllda mål:

- 1) Utvecklade AI-modeller samt databaser för laststyrning på fjärrvärmenät efter finjustering ("fine-tuning") och utvärdering.
- 2) Lönsamhetsanalys och kostnadsbesparingar i anknötning till energibesparingar och toppeffektreduktioner samt analys av primärenergifaktorer och miljöpåverkan i anknötning till energibesparingar på basis av hur energiproduktionen är idag och hur den uppskattas se ut år 2030.
- 3) Målet är att sprida ut resultatet både nationellt via workshop med seminarier och internationellt. Målet är också att öka kunskapen om energilagring i byggnadsstommen hos energileverantörer, fastighetsägare och förvaltare samt antikvarieexperter genom helhetsperspektiv på byggnaden som ett system.

1.3 OMFATTNING OCH AVGRÄNSNING


Projektet utvärderar potentialen för att förbättra termisk komfort, energieffektivitet och topptrimning av levererad uppvärmningseffekt i historiska byggnader genom utveckling av en AI-modell. Den föreslagna AI-modellen kan förutsäga värmebehovet i fjärrvärmen (FV) i förväg baserat på väderprognoser, en binär kalender för brukandet av byggnaden och interna laster, samt lagra fjärrvärme i byggnadens stomme inför kallare perioder. Den utvecklade AI-modellen har tre huvudsakliga funktioner som kan viktas av användaren:

- Optimal termisk komfort
- Optimal energi (minimera fjärrvärmeleveransen)
- Optimal effekt (kappa toppeffekter av fjärrvärmeleveransen)

På längre sikt är det tänkt att systemet ska fortsätta användas efter projektets avslut och att metodiken kan implementeras i andra äldre och kulturhistoriska byggnader.

Ett av syften med projektet har varit att kunna implementera och testa AI modellerna i styrsystemen hos fallstudiebygganden, Rådhuset i Gävle, men tyvärr lyckades det inte att praktiskt införa dessa, på grund av bristande villighet från fastighetsägaren och framförallt styrsystem-tillverkaren.

Förhoppningsvis kan projektet kompletteras med implementering av AI modellen i byggnadens styrsystem i framtiden.



2. GENOMFÖRANDE


Byggnadens som har använts som fallstudie är Rådhuset beläget i staden Gävle i mellersta Sverige. Rådhuset är en kulturmärkt byggnad från 1780-talet som nu används som kontorsbyggnad med en total användbar golvyta på 2100 m². Uppvärmning av utrymmen och tappvarmvatten sker genom fjärrvärme. Rummen värms med radiatorer och det sker även en eftervärmning av tilluften från två FTX-system.

För att kunna utveckla AI-modeller behövs en väl strukturerad (flerårig) datahistorik från energianvändning av byggnaden i fråga, med minimum timvis tidsupplösning. Energidata måste synkroniseras med väderdata. Data för inomhustemperatur, levererad fjärrvärme och värmevattnets framledningstemperatur samlas in från fastighetsautomations-systemet (BMS) Schneider-modell ZS101 (Schneider Electric, n.d.). Profiler för inomhustemperatur beräknades med hjälp av registrerade lufttemperaturer från zoner i BMS och har viktats från genomsnittliga värden över golvytan under mätperioden. Väderdata inklusive utomhustemperatur hämtades från Sveriges Meteorologiska och Hydrologiska Institut (SMHI). För att kunna utveckla AI-modeller sammanställs en längre (nästan ett och ett halvt år) strukturerad dataserie från Rådhuset enligt nedan:

1. Levererad timvis fjärrvärmeeffekt (kWh/h) för hela byggnaden – totala värmen inklusive uppvärmning av utrymmen och tappvarmvatten.
2. Inomhustemperaturer (°C) (timvis genomsnittligt golvytaviktad för hela byggnaden).
3. Framledningstemperatur, värmevattnets temperatur till radiatorer, (°C) (timvis genomsnittligt värde).
4. Timvis utomhustemperatur (°C).

Vi utvecklade olika maskininlärningsalgoritmer inklusive moderna djupinlärningsmetoder för att träna modeller baserade på insamlad data. I denna studie låg fokus på att optimera värdena för fjärrvärmeleverans för att upprätthålla en bekväm inomhustemperatur för en specifik byggnad. Målet var att identifiera en sekvens av framledningstemperaturer som minimerar levererad värme och/eller topp effekter samtidigt som inomhustemperaturen hålls inom börvärdesinställningar.

Tillvägagångssättet omfattar tre nyckelkomponenter: en generativ modell, en dynamisk modell (prediktionsmodellen) och en optimerare. Den generativa modellen genererar olika sekvenser av framledningstemperaturer med hänsyn taget till föregående dagars data. Prediktionsmodellen förutsäger inomhustemperaturer baserat på olika indata, inklusive framledningstemperatur och prognostiserad utomhustemperatur. Slutligen utnyttjar optimeraren den genererade sekvensen för att hitta optimala framledningstemperaturer, vilket säkerställer effektiv styrning av fjärrvärme för förbättrad komfort och energioptimering. Dessutom utvecklade vi en grundläggande linjär modell (en linjär värmekurva som efterliknar den verkliga i byggnaden) för jämförelseändamål. En detaljerad beskrivning av AI-modellen ges i bilaga A.



3. RESULTAT

Tabell 1 presenterar uppmätta och AI-modellgenererade data för årlig uppvärmning av fallstudiebyggnaden (Rådhuset).

Tabell 1: Årligt uppmätt och beräknad fjärrvärme, FV, (kWh)

	Fjärrvärmeanvändning (kWh)	Skillnad mot uppmätt fjärrvärmeanvändning (%)
Årlig uppmätt FV, år 2021	233 238	100,0
Årlig FV - beräknad av linjär modell	238 624	102,3
Årlig FV - beräknad av AI-optimal modell för termisk komfort	222 691	95,5
Årlig FV - beräknad av AI-optimal modell för energi	145 364	62,3
Årlig FV - beräknad av AI-optimal modell för effekt	166 517	71,4
Årlig sparad energi - beräknad av linjär modell	-5 386	-2,3
Årlig sparad energi - beräknad av AI-optimal modell för termisk komfort	10 547	4,5
Årlig sparad energi - beräknad av AI-optimal modell för energi	87 874	37,7
Årlig sparad energi - beräknad av AI-optimal modell för effekt	66 721	28,6

Fjärrvärmen (FV) i Gävle, tillhandahållen av det lokala energiföretaget Gävle Energi, genereras helt från förnybara källor. Produktionsblandningen är 100% förnybar, främst bestående av spillvärme från industrier samt kondensationsvärme från rökgaser och värme från kraftvärmeverk (CHP) som drivs med biobränslen som bark, returträ och en liten mängd flis, samt små mängder bioolja. Denna produktionsmetod resulterar i en låg miljöpåverkan, motsvarande 7g CO₂-ekvivalenter per kilowattimme (kWh) år 2023; år 2021 var det 6g CO₂-ekvivalenter per kilowattimme (kWh) (Gävle Energi, n.d.-a). Som ett resultat motsvarar den totala mängden FV som levereras till Rådhuset cirka 1,4 ton CO₂-ekvivalenter årligen.

Dessutom är prisbilden för detta miljömedvetna fjärrvärmesystem satt till 0,526 svenska kronor per kWh, tillsammans med vissa fasta avgifter för år 2024 (Gävle Energi, n.d.-b). Följaktligen, enligt den årliga sparade fjärrvärmenergi (kWh) och -toppar (kWh/h) som presenteras i Tabell 1 ovan resp. Tabell 2 i Bilaga B, kan optimering av energi- och effektm modeller generera ungefär 38 respektive 29% energibesparing, motsvarande en minskning av värmekostnaderna med cirka 46 000 respektive 35 000 svenska kronor (motsvarande 22 resp. 17 kr/m²) baserat på det allmänna FV priset hos energileverantören.


Men för företagskunder finns det även andra delar i pristariffen såsom kapacitetsavgift, säsongsuppdelat energipris samt ett volymavdrag. Kapacitetsbehov är beräknat enligt en linjär prognos av byggandens energibehov per dygn när det är minus 10 grader °C i utetemperatur.



Beräkningen baseras på dygnsförbrukningar för byggnaden som uppmätts (måndag – fredag) under närmast föregående period, november – mars. För 2024 är Kapacitetspris = 37,12 kr/kWh. Volymavdraget baseras på fjärrvärmeleveransens omfattning per ackumulerat kalenderår och anläggning. Om fjärrvärmeanvändningen är större än 100 MWh görs ett avdrag på priset varje månad. En mer detaljerad kostnadsanalys med hänsyn till 2024 tariff av energibolaget presenteras i Bilaga C.

I Figur 1 sammanställs ett varaktighetsdiagram för tillförd FV. Notera att den linjära predikteringsmodellen kan öka FV-behovet något, vilket leder till en efterföljande ökning av värmekostnaderna. Tabell 2 i Bilaga B visar att de 10 högsta effekttimmarna blir något högre med den linjära modellen, medan AI-modellerna kan minska dessa med cirka 6%. AI-modellen med värmeeffektoptimering har en något högre potential för att kapa de 10 högsta FV-effekttopparna och resulterade i ca 7% minskning. För mer detaljerade resultat se Bilaga B.

Som komplement till energisignaturdiagrammen i Bilaga B illustrerar Figur 1 varaktighetsdiagram för de studerade fallen. Figuren visar även energibesparingspotentialen som AI-modellens prediktioner medför, eftersom arean under respektive kurva representerar årlig total energianvändning. Figuren indikerar det som nämnts ovan om att den linjära modellen ibland till och med förstärker topparna i leverans av fjärrvärme, eftersom den saknar förmåga att leverera FV i förhållande till byggnadens och uteklimatets varierande dynamik.



Figur 1: Varaktighetsdiagram för den tillförda fjärrvärmens (District Heating, DH) för uppvärmning och varmvatten för fallstudiebyggnaden, Rådhuset i Gävle, inklusive uppmätta samt modellberäkningar.

4. HUR SKA RESULTATEN KOMMA TILL ANVÄNDNING

Vår idé är att presentera denna fallstudie som ett praktiskt görbart exempel på energilagring i kulturhistorisk byggnadsstomme som en resurseffektiv innovativ metod för energi- och effekttoppbesparingar med bibehållen termisk komfort, och inte minst sprida resultatet bl. a. genom deltagande i internationella och nationella konferenser/seminarier.

Målsättningen är att projektets resultat skall få stor inverkan på effektivare energianvändning i kulturhistoriska byggnader via lagring av energi i byggnadsstommen, samt höja kunskapen om metodens potential och miljöpåverkan. Metoden kan utvecklas och automatiseras till att bli en beprövad metod för äldre kulturhistoriska byggnader, särskilt "tunga" sådana, med stor termisk massa. Resultaten ska även kunna användas av fastighetsägare som tredjepartsinformation samt bidra till att vara en form av kompletterande beslutsunderlag för byggnadsförvaltare och antikvariska experter. Eventuella befintliga styr- och regleringsutrustningens kan uppdateras via automatiska anpassning av reglerstrategin, även för förbättrad termisk komfort inne.


Den utvecklade AI-modellen med Graphic User Interface (GUI) i den här studie kan vara vägledande för att utveckla energioptimeringstjänster och produkter samt vid beslut om vilka lösningar som är långsiktigt lämpligast ur energi- och miljöperspektiv. Projektet bidrar till en mer flexibel och robust energitillförsel med ett jämnare effektbehov, vilket gagnar både energibolag, fastighetsägare samt miljö, då dyrare och eventuella tillfälliga fossilberoende energiresurser kan undvikas, vilket leder till lägre växthusgasutsläpp.

Som en liten AI modelleringsguide behövs följande etapper för att kunna skapa och träna en AI modell:

För att kunna utveckla AI-modeller behövs en väl strukturerad (flerårig) datahistorik för energianvändning och temperaturer från inommiljön, utemiljön och framledningstemperaturer för den aktuella byggnaden, med minimum timvis tidsupplösning. Energi- och temperaturdata måste synkroniseras med väderdata. Datainsamling ska ske i samråd med fastighetsägare och energibolaget och det är utmanande för att det kan saknas data för vissa perioder och ibland måste data tolkas och omsorteras för att kunna användas för träning av AI modeller. När det gäller fjärrvärme, som är i fokus i denna studie, kan via så kallade DUC (DataUnderCentraler) hela värmeförselen i varje fjärrvärmecentral styras på ett mer smidigt och centralt sätt, dvs. energi och effekttillförsel samt framlednings- och innetemperatur kan avläsas och valideras i realtid centralt från energibolaget.

Efter datainsamlingen kan olika maskininlärning (ML)-algoritmer inklusive djupinlärningsmetoder utvecklas och prövas på uppmätta energi- och effektdata hos byggnaden, för att få modeller som med hög precision kan förutsäga effekttoppar. För att avgöra vilken typ av ML modeller som är lämpligast bör dataserien inklusive effekttoppar undersökas samt eventuella avvikelser mellan modeller och mätdata tolkas och kategoriseras.

Laststyrningsmodellernas potential för att minska toppeffekter bör prövas och valideras mot mätdata (avvikelse-detektering). För detta kommer de utvecklade ML-modellerna att användas, för att korrigera eventuella avvikelser i en iterativ process. För att förbättra robustheten, utvecklas osäkerhetsmedvetna ML-modeller med hjälp av vilka AI-systemet kan växlas till att kontrollera i säkert läge när osäkerheten för ML-modellen är hög. Probabilistiska modeller byggs för att hantera osäkerheter som härrör från brist på data, till exempel för låga inomhustemperaturer (utanför komfortintervallet) såväl som extremfall av kallt väder utöver vad som redan finns i den uppmätta dataserien. AI modellen "utbildas/tränas" för att tillåta algoritmen att upptäcka toppeffekter i god tid



och implementera en lämplig åtgärd eller beslutssekvens för att styra värmeförsörjning och minska toppeffekten med bibehållen termisk komfort. Algoritmen erhåller optimal hantering av osäkerheter baserade på algoritmer för förstärkningsinlärning (RL) och mer specifikt modellprediktiv kontroll (MPC). Denna lösning bygger på att uppnå maximerad total belöning genom att använda offline data som samlades in i föregående steg. Sådana RL-algoritmer som lär sig av offline-data istället för online trial-and-error är särskilt lämpliga för vår problemformulering eftersom en behaglig rumstemperatur måste uppnås hela tiden, även under RL-träning.

Ett detaljerat uppgifts- och arbetspaket behövs för att utveckla AI-modellen, där all tillgänglig indata framgår samt förväntade utdata inom respektive tidsram. En plan bör tas fram för eventuell modellverifiering, finjustering och validering av modeller.

Tidsatta arbetspaket förslås enligt följande:

1) Design av ML lösningar samt Datainsamling

Utvalda byggnader uppvärmda med fjärrvärme. Energibolaget som levererar värmen till byggnaderna har möjligheter att styra värmemängden och temperaturen på värmevatten via DUC (dataundercentralen) och styrning (som finns i varje fjärrvärmecentral) med möjlighet att tillfälligt höja eller sänka temperaturen. Data inkluderar levererad energi och effekt, systemtemperaturer, flöden samt inne- och utetemperatur och eventuellt kompletterande mätdata t ex verksamhets- och fastighetsel. Tillräcklig samlade data (kanske med två år datahistorik för samma byggnad) ska struktureras i en databas med olika kategorier som ska användas för att utveckla och träna maskininlärningsmodeller. Förutom indata görs en skiss av förväntade resultat, prestanda, noggrannhet, modellverifiering, möjlighet för finjustering och modellvalidering.

Förväntat resultat: En databas av strukturerat samlat indata inklusive levererad energi och effekt, temperaturer, flöden samt inne- och utetemperatur. Information om hur energilagringen kan påverka operativa temperaturen hos lokaler och uppvärmning. I denna etapp framgår även hur byggnadens tidskonstant påverkar värmedistribution i byggnaden samt uppskattningar av byggnadens lagringskapacitet.


2) Modellträning och utforskning/utvärdering av ML modeller

Med hjälp av Framåt Dynamisk Modell Träning (inlärning) använder vi samlade indata (offline data) för att träna olika djupinlärningsmodeller såsom multilayer perceptron (MLP), Convolutional Neural Networks (CNN) och transformatorer. Modellerna utforskas och prövas för att koppla byggnaden energilagring till innetemperatur, termisk komfort och energianvändning i olika väderförhållanden.

Syftet med framåtriktad modellinlärning är att få en modell med följande input- och outputdata:

- Aktuella/tillgängliga mätdata: aktuella temperaturer inomhus och utomhus, nuvarande väderförhållanden, värmeffekt/effekt (både framledningstemperatur, returtemperatur och vattenflöde) samt en binär kalender för uppskattad personnärvaro.
- Sekvens av framtida indata (prognos): timvis väderprognos för en given tidshorisont (t.ex. under det närmaste dygnet eller veckan) samt en binär kalender för uppskattad personnärvaro.
- Konstanta parametrar: byggnadens termiska parametrar samt möjligtvis fönsterparametrar, apparater och belysning.
- Styr signaler: levererad fjärrvärme per timme till byggnaden för samma tidshorisont.

Modelloutput:



- Beräknad (prognoserat) timvis inomhustemperatur för samma tidshorisont (t.ex. under det närmaste dygnet eller veckan).

Efter utforskning av olika modeller väljs lämpligaste algoritmen och en första version av modellen kan utvecklas.

Modellen analyseras avseende avgörande parametrar och deras intervall och besparingsmöjligheter.

3) Model predictive control – kontrollstrategi

Utvecklad maskininlärningsmodell kommer också utvärderas för automatiserad metod så att den självanpassas till olika scenarier för att studera energibesparingar och minskning av effektbehov. Indata avser även att möjliggöra ändring i byggnadernas systeminställningar genom styr- och reglerteknik för att fastställa byggnadens dynamik baserad på olika scenarier och olika väderförhållanden för uppvärmning.

Med den utvecklade modellen kan vi nu hitta en sekvens av levererad fjärrvärme (t.ex. var 30:e minut under det närmaste dygnet) som gör att den aktuella rumstemperaturen ligger så nära börvärdet som möjligt. Kontrollen kan utföras av Modell Prediktiv Kontroll (MPC) som är en avancerad kontrollstrategi baserad på användningen av den utbildade/tränade framåt-dynamiska modellen för att direkt hitta sekvensen för levererad fjärrvärme. Här tränar vi inte någon ny modell utan använder den redan utbildade framåtmodellen för att hitta optimala åtgärder (optimal fjärrvärmeleverans).

De initiala data som vi använder för att träna den dynamiska modellen (offline-data) kan vara annorlunda än de data som kontrollanten använder. Därför är det alltid en bra idé att finjustera framåtmodellen ytterligare med de senaste samlade indata (med MPC kontrollstrategi som är i fokus i den här etappen).


Förväntat resultat: Optimering av styrsignaler via MPC.

4) Modelloptimering via hyperparameter-inställning och redovisning av API (Application Program Interface).

För att optimera modellen kan hyperparametrar väljas för att felsöka modellen och utföra felanalyser exempelvis med överanpassning av data till en felsökningsmodell. Olika modellkomponenter ska utvärderas med respektive inputdata för att testa förstärktalgoritmen. Eventuella problem med datakvalité samt överanpassning med indata ska lösas. Dessutom behövs en API (Application Program Interface) eller en applikation för att övervaka styrmodeller i realtid baserad på nya indata (inklusive både träning och testdata).

Kostnadsanalys/lönsamhetsanalys av olika lagringspotential med hjälp av utvecklade modeller utvärderas för att hitta vilka lösningsalternativ för energilagring i byggnaden som ger:


- Lägst resursanvändning – primärenergi
- Lägst miljöpåverkan – växthusgasutsläpp
- Högst termisk komfort
- Högst lönsamhet och besparingspotential



Förväntat resultat: De styrmodeller som medför lägst resursanvändning och miljöeffekt genom effektiv energianvändning i byggnader kommer att presenteras utifrån primärenergianvändning och växthusgasutsläpp.

En mer detaljerad beskrivning av modellen är presenterad i Bilaga A: Beräkningsproceduren och utvecklingen av AI-modellen.

Därutöver presenteras det grafiska användargränssnittet (GUI) som utvecklats för modellen i Bilaga D: Graphic User Interface (GUI) till den presenterade AI modellen.



5. DISKUSSION


Predikteringar för fjärrvärme (FV) från den linjära modellen överensstämmer nära med de uppmätta fjärrvärme, till skillnad från prognosberäkningar av AI-modellen. Prognosberäkningar från de optimala energi- och effekt AI modellerna indikerar lägre nivåer av FV jämfört med den linjära modellen, särskilt märkbart under sen vår och tidig höst. Denna diskrepans kan orsakas av de linjära börvärdeinställningar, känt som värmekurvan, som är inbäddat i installerade värmesystem. Värmekurvan etablerar en direkt korrelation mellan framledningstemperaturen i värmesystemet och utomhustemperaturen. Å andra sidan har AI-modellen förmågan att optimera levererad FV genom att ta hänsyn till historiska data av levererad FV, samt inomhus- och utomhustemperaturer.

Som presenterats i Tabell 1 samt Tabell 2 (i Bilaga B), ledde optimeringen av energi och värmeeffekt med AI-modellen till olika besparingar. Detta kan till en början verka motstridigt, med tanke på att båda modellerna syftar till att optimera levererad FV och minska effekttoppar. Orsaken bakom denna diskrepans ligger i metoderna för dalfyllnings- och topplastminimeringstekniker (valley filling and peak shaving) som används av energi- och effektmодellen. Även om dessa tekniker effektivt minskar topparna i levererad värme kan de samtidigt leda till en ökning av energianvändningen under några timmar, eftersom modellen försöker minska topparna och leverera en jämnare FV under kommande timmar utan att sänka eller höja innetemperaturen för mycket. Detta inträffar eftersom värmeförluster också eskalerar under lagringsprocessen, vilket resulterar i en tillfällig höjning av inomhustemperaturen på grund av högre levererad uppvärmning av utrymmen. Figur 1 illustrerar inte denna fenomen eftersom den föreslagna AI-modellen även sänker inomhustemperaturen, i linje med de angivna inställda börvärdena för innetemperaturen, för att spara uppvärmningsresurser. Följaktligen minskar AI-modellen både uppvärmningseffekttoppar och minimerar, det vill säga optimerar, den totala FV-leveransen genom att upprätthålla inomhustemperaturen nära de inställda börvärdena och därmed bibehålla termisk komfort.

Även om det finns en potentiell ökning av total energilagring kan de ekonomiska besparingarna i samband med topptrimning fortfarande vara betydande, särskilt när andra energisparåtgärder inte genomförs. Kostnadsminskningarna kommer från besparingar i användningen av reservanläggningar och antagandet av mindre anläggningar för att möta toppbelastningar (Vandermeulen et al., 2018).


Den förväntade minskningen av totala utsläpp som resultat av optimering av FV-försörjning genom AI-modellen förväntas vara betydande. Dessa påverkningar skulle kunna förstärkas ytterligare om liknande optimeringar av AI-modeller tillämpas på alla sammanlänkade byggnader inom ett FV-nätverk, vilket undviker behovet av mindre miljövänliga energikällor (för att uppfylla extra behov vid topplasttimmar).

Generellt sett är inomhustemperaturen högre under arbetstid jämfört med icke-arbetstid, en åtgärd som vidtas för att säkerställa personalens termiska komfort. Denna temperaturreglering styrs av specifika inställda värden som tilldelats AI-modellen för underhåll av inomhustemperaturen: 21°C under arbetstid (06:00-18:00) och 18°C under icke-arbetstid (18:00-06:00 på vardagar samt under helger och helgdagar). Den studerade byggnaden används som kontorsbyggnad och därför är dessa inställda värden utformade för att överensstämja med de boendes komfortpreferenser under olika tidsintervall.



Det är tydligt att den uppmätta inomhustemperaturen når sina lägsta punkter under de kallare vinterdagarna, medan de inomhustemperaturer som förutsägs av AI-modellen konsekvent är cirka 1 grad högre än de uppmätta värdena. De uppmätta inomhustemperaturerna kan sjunka under 21 grader och påverka personalens termiska komfort under vinterdagarna, medan AI-modellens förutsägelser särskilt ligger runt inställda börvärden under arbetstid och icke-arbetstid även under de kallaste dagarna i januari och februari. Till exempel kan den förutsedda inomhustemperaturen sjunka under 21 grader under några timmar under arbetstid, men de är fortfarande över 20 grader enligt inställda börvärden. Dessutom visar den optimala energi- och effektmodellen under hela året jämnare inomhustemperaturer jämfört med de uppmätta temperaturerna, dvs. AI-modellens förutsägelser är högre under de kallaste dagarna på vintern, medan de uppmätta värdena ibland är under de inställda värdena, och AI-modellens förutsägelser är lägre under våren och hösten, jämfört med de uppmätta temperaturerna. På så sätt försöker AI-modellen att sätta inomhustemperaturen så mycket som möjligt över de inställda värdena och samtidigt optimera leveransen av FV. Dock är förutsägelserna från den optimala termiska komfort AI-modellen närmare de uppmätta FV-förutom under de kallaste dagarna i januari och februari, eftersom modellen prioriterar den termiska komforten och har striktare inställningar för att hålla inomhustemperaturen över de inställda börvärdena.

I den här studien används inomhustemperaturer som viktas efter golvyta, och i framtiden kan vi särskilja data per områden som är i direkt kontakt med utomhusmiljön. En betydande begränsning av AI-modellen uppstår på grund av bristen på mångfald i träningsdata. Med tanke på att data härstammar från en kompetent regulator, hamnar inomhustemperaturen främst inom ett snävt intervall, särskilt under den kalla delen av året. Dessutom blir data knapphändig för mycket kalla utomhusförhållanden, eftersom dessa inträffar en eller ett par dagar per år, om alls. Följaktligen står modellen inför betydande utmaningar när det gäller att göra precisa förutsägelser när inomhustemperaturen förväntas avvika utanför detta etablerade intervall, såsom förutsägelse av extremt låga temperaturer.




6. SLUTSATSER

Denna fallstudie utforskar det innovativa användandet av en historisk stenbyggnads stomme som ett värmebatteri, med användning av artificiell intelligens (AI) och maskininlärningsmodeller. Tillvägagångssättet innebär kontroll av värmetillförsel baserad på väderprognoser och predicerad personnärvaro (arbets- resp. icke-arbetsstimmar) för optimering av energianvändning och effektbehov samtidigt som termisk komfort bibehålls. Studien visar på betydande besparingar både vad gäller total och toppenergianvändning, och tyder på tillämplighet för liknande fall. Prediktionsmodellen använder en uppsättning konvolutiva neurala nätverk (Convolutional neural networks) som tränas genom övervakad inläring. Simuleringsresultaten visar potential för besparingar på 38% och 29% i årlig fjärrvärme, beräknat av de optimala energi- och effekt-AI-modellerna, vilket visar på kostnadsbesparingar på cirka 46 000 respektive 35 000 SEK (22 och 17 SEK/m²) för den studerade byggnaden. Samma optimerande energi- och värmeeffekt-AI-modeller kan generera ungefär 23% minskning av toppvärmeeffekt i medeltal över året, beräknat per 24 timmar. Vidare utvecklades en linjär modell (likt den verkliga) för jämförelseändamål och denna bidrog till ökade uppvärmningskostnader genom att något öka behovet av fjärrvärme (FV). Dessutom visades det att AI-modellerna kan minska de 10 högsta effekttopparna per timme med cirka 6% för byggnaden.

I termer av miljöpåverkan kan de potentiella besparingarna i årlig sparad fjärrvärmeenergi och effekttoppar leda till minst lika stora besparingar i de totala utsläppen som orsakas av produktion och leverans av FV, även om fjärrvärmeproduktion i detta fall är från hållbara och förnybara källor. Den förväntade minskningen av utsläpp genom att optimera FV-leveransen genom AI-modellen skulle vara ännu större om den tillämpades på alla sammanlänkade byggnader i ett FV-nätverk, vilket skulle minska behovet av mindre miljövänliga energiproduktionskällor.

I framtiden kan den föreslagna AI-modellen genomgå testning och verifiering genom implementering i en verklig byggnad, specifikt Rådhuset i Gävle, i samarbete med fastighetsägaren. Vidare skulle integration i det befintliga fastighetsautomationssystemet möjliggöra datainsamling och modellprediktioner i realtid. Systemet skulle kunna generera signaler och meddelanden till fastighetsskötare och användare, för att uppmana till justeringar av värmesystemen vid oväntade/oönskade avvikelser i värmestyrningen. Ytterligare parametrar, såsom solstrålning, skulle kunna förbättra modellen om tillförlitliga data fanns tillgängligt. Känslighetsanalys skulle kunna bedöma modellens prestanda med och utan dessa extra parametrar. För närvarande använder modellen areaviktad inomhustemperatur för att utveckla förutsägelser, med resultat som representerar fjärrvärme för hela byggnaden, centralt styrd av fjärrvärmeväxlaren. Framtida utveckling av modellen skulle kunna utvidga dess prestanda till att styra inomhustemperaturer i enskilda rum, förutsatt att varje rums radiator är utrustad med fjärrstyrd termostat för separat temperaturreglering. I framtiden kan presenterad AI-modell ha tillämpningspotential att utvecklas för att ansluta flera byggnader inom ett distrikt och även över hela fjärrvärmenätet för att optimera FV-leveransen. Vidare erbjuder integration av FV-nätverket med elnätet möjligheten att synkronisera och optimera hela energisystemet, inklusive olika lagringssystem, både termiska och elektriska.



7. PUBLIKATIONSLISTA

Projektet resulterat i följande publikationer:

Konferensdeltagande:

Programkonferens för Spara och bevara, 20-21 Mars 2023, Uppsala


Slutkonferens för Spara och bevara, 20-21 Mars 2024, Visby, [Länk](#).

Poster presentation: 3rd International Sustainable Energy Conference, 10 - 11 April 2024, Graz, Austria, [Länk1](#) samt [länk2](#).

Vetenskapliga artiklar:


Hayati, Abolfazl, Jan Akander, and Martin Eriksson. 2022. "A Case Study of Mapping the Heating Storage Capacity in a Multifamily Building within a District Heating Network in Mid-Sweden" *Buildings* 12, no. 7: 1007. <https://doi.org/10.3390/buildings12071007>

Akander, Jan, Hossein Bakhtiari, Ali Ghadirzadeh, Magnus Mattsson, and Abolfazl Hayati. 2024. "Development of an AI Model Utilizing Buildings' Thermal Mass to Optimize Heating Energy and Indoor Temperature in a Historical Building Located in a Cold Climate" *Buildings* 14, no. 7: 1985. <https://doi.org/10.3390/buildings14071985>




8. REFERENSER

- Akander, J. (2000). *The ORC-method. Doktorsavhandling*. KTH Royal Institute of Technology.
- Calikus, E., Nowaczyk, S., Sant'Anna, A., Gadd, H., & Werner, S. (2019). A data-driven approach for discovering heat load patterns in district heating. *Applied Energy*, 252, 113409. <https://doi.org/https://doi.org/10.1016/j.apenergy.2019.113409>
- Gävle Energi. (n.d.-a). *Miljöriktig fjärrvärme*. Retrieved February 15, 2024, from <https://www.gavleenergi.se/om-oss/miljo-och-hallbarhet/fjarrvarme/>
- Gävle Energi. (n.d.-b). *Priser och prisjämförelser*. Retrieved February 15, 2024, from <https://www.gavleenergi.se/fjarrvarme/priser-och-prisjamforelser/>
- Hayati, A., Akander, J., & Eriksson, M. (2022). A Case Study of Mapping the Heating Storage Capacity in a Multifamily Building within a District Heating Network in Mid-Sweden. *Buildings*, 12(7), 1007.
- Karlsson, J. (2012). *Possibilities of using thermal mass in buildings to save energy, cut power consumption peaks and increase the thermal comfort*. Lund Institute of Technology, Division of Building Materials.
- Ni, Z. (2023). *A Digitalization Framework for Smart Maintenance of Historic Buildings*. Linköping University Electronic Press.
- Ni, Z., Liu, Y., Karlsson, M., & Gong, S. (2022a). Enabling Preventive Conservation of Historic Buildings Through Cloud-based Digital Twins : A Case Study in the City Theatre, Norrköping. *IEEE Access*, 10, 90924–90939. <https://doi.org/10.1109/access.2022.3202181>
- Ni, Z., Liu, Y., Karlsson, M., & Gong, S. (2022b). Link historic buildings to cloud with internet of things and digital twins. *The 4th International Conference on Energy Efficiency in Historic Buildings*, 229–235.
- Ni, Z., Zhang, C., Karlsson, M., & Gong, S. (2023). Leveraging Deep Learning and Digital Twins to Improve Energy Performance of Buildings. *ArXiv Preprint ArXiv:2305.04498*.
- Ni, Z., Zhang, C., Karlsson, M., & Gong, S. (2024). A study of deep learning-based multi-horizon building energy forecasting. *Energy and Buildings*, 303, 113810. <https://doi.org/https://doi.org/10.1016/j.enbuild.2023.113810>
- Norén, A., Akander, J., Isfält, E., & Söderström, O. (1999). The effect of thermal inertia on energy requirement in a Swedish building-results obtained with three calculation models. *International Journal of Low Energy and Sustainable Buildings*, 1, 1–16.
- Schneider Electric. (n.d.). *Schneider Electric. ZS 101 ZS 106 Wall Modules*. Retrieved February 9, 2024, from <https://www.se.com/se/sv/download/document/000316614/>
- Sollich, P., & Krogh, A. (1995). Learning with ensembles: How overfitting can be useful. *Advances in Neural Information Processing Systems*, 8.
- Vandermeulen, A., van der Heijde, B., & Helsen, L. (2018). Controlling district heating and cooling networks to unlock flexibility: A review. *Energy*, 151, 103–115.
- Verbeke, S., & Audenaert, A. (2018). Thermal inertia in buildings: A review of impacts across climate and building use. *Renewable and Sustainable Energy Reviews*, 82, 2300–2318.



Bilaga A: Beräkningsproceduren och utvecklingen av AI-modellen

Inom projektet utvecklades olika maskininlärningsalgoritmer inklusive avancerade djupinlärningsmetoder för att träna modellerna med insamlade data. Målet var att optimera fjärrvärmeleverans (minskad energianvändning och toppeffekter) och samtidigt upprätthålla en bekväm inomhustemperatur (termisk komfort) hos en kulturhistorisk värdefull byggnad. Genom att identifiera sekvenser av framledningstemperaturer, vilka minimerar levererad värme med låga toppeffekter samtidigt som inomhustemperaturen hålls över börvärden under de kommande 48 timmarna med prognostiserat väder (utetemperaturer). Tillvägagångssättet illustreras i figur 2 och omfattar tre nyckelkomponenter: en generativ modell (conditional Variations Auto-Encoder, cVAE), en prediktionsmodell (Dynamic model) och en optimerare (Optimizer). Den generativa modellen genererar olika sekvenser av framledningstemperaturer hos värmevattnet, som distribueras till radiatorsystemet och eftervärmning av tilluft, med hänsyn till historiska data. Prediktionsmodellen förutsäger inomhustemperaturer baserat på olika laster (kalender, dygnsplan och börtemperaturer), inklusive framledningstemperaturer och prognostiserade utomhustemperaturer. Slutligen utnyttjar optimeraren den genererade sekvensen för att hitta optimala framledningstemperaturer, vilket medför effektiv styrning av fjärrvärmeförseln för förbättrad termisk komfort och energioptimering. Därutöver utvecklades en grundläggande linjär modell för jämförelseändamål; denna modell avspeglar hur värmeförseln i den studerade byggnaden styrs i dagens läge.



Figur 2: Schematisk illustration av AI-modelleringsmetoden som används för predikterad fjärrvärmeförsel och inomtemperaturer.

Nertill framgår detaljerade beskrivningar av de ingående komponenterna.

Dynamic model (Prediktionsmodell)

Prediktionsmodellen tar in byggnadens inomhus- och utomhustemperaturer samt levererad FV och framledningstemperaturer under de senaste timmarna (i simuleringarna satt till 7 dygn men kan anta andra värden), tillsammans med prognostiserade utomhustemperaturer och predikterade framledningstemperaturer hos värmevatten för de kommande 48 timmarna. Utdata från prediktionsmodellen är den predikterade inomhustemperaturen och fjärrvärmeförseln för nästa timme.

Modellen beaktar även eventuella begränsningar och börvärden som tilldelats inomhustemperaturinställningar, 21°C under arbetstid (kl 06:00-18:00) och 18°C under icke-arbetstid (kl 18:00-06:00 under vardagar och alla timmar under helger och helgdagar). I båda fallen tillåts temperaturen understiga börvärdena med maximalt 1 grad några timmar under de kallaste vinterdagarna. Vidare bör den förutsagda FV aldrig bli negativ, och den lägsta framledningstemperaturen är satt till 18°C enligt den egentliga värmekurvan. Maximala framledningstemperaturen är inställd på 93°C enligt uppmätt data.


Prediktionsmodellen består av en ensemble av konvolutionella neurala nätverk (Convolutional Neural Networks, CNN), vardera bestående av totalt 5 lager; tre 1D-convolutional-lager följt av två fullständigt anslutna lager. Den tränas genom övervakad inlärning och använder medelkvadratfelet (MSE) som förlustfunktion. Att använda en ensemble av modeller är vanligt inom maskininlärning, där flera individuella modeller, oftast av samma typ (i det här fallet flera CNN-modeller), kombineras för att bilda en enhetlig och mer robust prediktionsmodell. Denna kombination ger en spännvidd av resultat som kan sammanfattas genom tekniker såsom genomsnittsbildning, omröstning eller viktad genomsnittsbildning (Sollich & Krogh, 1995).

Ensemblens utdata ger en föreställning om sannolikheten eller tillförlitligheten hos förutsägelsen/predikteringen. Detta beror på att ensemblen kombinerar predikteringar från olika individuella CNN modeller, där var och en har sina egna styrkor och svagheter, och denna mångfald gör att ensemblen kan fånga upp olika aspekter från indatadistributionen/-fördelningen. Därmed ger ensemblen en bred utdata för bedömning av osäkerheter och ge probabilistiska uppskattningar hos varje prediktion. Detta är särskilt värdefullt i beslutsprocesser där att ha en tillförlitlig mätning tillåter oss att fatta beslut med ett mer informativt underlag, vilket beaktar potentiella osäkerheter och tillförlitligheter hos modellens prediktioner i olika scenarier.

Varje CNN i ensemblen tränas separat genom att sampla datapartier (batches) ur träningsdatasetet. Modellens parametrar optimeras sedan med stokastisk gradientnedstigning (SGD) över de samlade datapartierna (batches). SGD optimerar globala förlustfunktionen hos CNN, dvs hur mycket modellens prediktion avviker från motsvarande mätvärden, i form av MSE, för att fastställa modellparametrarna.

Generative model (Generativ modell)

Användningen av data från den generativa modellen gör det möjligt för optimeraren att få indata från prediktionsmodellerna som är tillförlitlig och undviker data som ligger utanför en fördelning som kan förhindra korrekta predikteringar. Dessutom säkerställer optimeraren en tillförlitligare leverans av temperaturutdata till byggnaden genom att nära anpassa dem med tidigare levererade värden. Den generativa modellen är en villkorlig variationsautokodare (conditional Variational Autoencoder, cVAE) som genererar en sekvens av framledningstemperaturer, beroende av en given variabel (i det här fallet temperaturvärden för framledningen och en slumpmässigt utvald latent vektor från en normalfördelning). Villkorliga indata inkluderas för att bibehålla kontinuiteten mellan temperaturvärdena vid olika tidpunkter. Det är viktigt att notera att de latent variablerna inte har någon fysisk betydelse; de fungerar helt enkelt som indata till den generativa modellen för att generera olika sekvenser.




Optimizer (Optimerare)

Optimeraren syftar till att hitta en optimal sekvens av framledningstemperaturer för att bibehålla inomhustemperaturen inom ett angivet intervall, främst genom börvärden som inte eller endast tillfälligt kan underskridas. Dessutom minimeras medel- och maximala FV-värden som sekundära mål för att spara energi, effekttoppar och därmed minska kostnader. Höga FV-värden, även under korta perioder, kan vara kostsamma, så det är viktigt att i möjligaste mån minska både medelvärden och toppvärden (effekt). Slutligen läggs en straffterm till som ett mått på oenighet i utdata från de dynamiska modellerna i ensemblen. Sammanfattningsvis har optimeraren tre mål, dvs. att minimera: (1) medelvärdet för den levererade fjärrvärmens, (2) det högsta värdet (topplasteffekt) för fjärrvärmens, och (3) osäkerheten hos prediktionen från den dynamiska modellen.

Optimeringen utförs med hjälp av "random shooting" genom den generativa modellen. Ett stort antal latent värden (t.ex. 1000) väljs slumpmässigt från standardnormalfördelningen. Dessa prover skickas sedan till den generativa modellen, som genererar sekvenser av framledningstemperaturer. Sekvenserna utvärderas sedan med hjälp av prediktionsmodellen för att beräkna kostnaden ("straffet") för varje sekvens baserat på en målfunktion. Sekvensen med lägst kostnad betraktas som de optimala FV-värdena för de kommande timmarna. Optimeringsprocessen kan utföras på en timme eller gradtimme basis, beroende på frekvensen för justeringar av framledningstemperatursekvenserna.

Piece-wise linear model (Styckvis linjär modell)

För att utvärdera effektiviteten hos det föreslagna neurala nätverksansatsen implementerades en styckvis linjär modell som kartlägger utomhustemperaturen gentemot den levererade fjärrvärmens, optimerad genom stokastisk gradientnedstigning (SGD). Optimeringen utförs genom att köra SGD på alla datapartier (batches) som samplats ur hela träningsdatasetet.




Bilaga B: Fortsättning av resultat

Tabell 2 presenterar data för uppmätta, linjära modellens och AI-modellernas predikteringar för årlig uppvärmning av utrymmen (inklusive tappvarmvatten) och sparade (kapade) effekttoppar. Fjärrvärmedata har mätts och simulerats per timme, vilket innebär att enheten är kWh för uppvärmning och kWh/h för effekttopparna. Den årliga fjärrvärmeenergitillförseln har beräknats per timbasis. För att uppskatta sänkningen av värmeeffekt har denna beräknats utifrån de maximala dagliga topparna hos fjärrvärmens (kWh/h) per dygn (24 timmar), och besparingen är skillnaden mellan AI-modellens prediktering och den levererade (uppmätta) fjärrvärmens. För att ytterligare analysera minskning av effekttoppar har 2021 års tio-i-topp toppeffektbehov per timme (kWh/h) sammanställts för de olika fallen.


Priset för Gävle Energi's fjärrvärmesystem är satt till 0,526 svenska kronor per kWh tillsammans med vissa fasta avgifter för år 2024 (Gävle Energi, n.d.-b). Följaktligen, enligt minskningen av årlig energianvändning (kWh) och effekttoppar (kWh/h) som presenteras i Tabell 2, kan AI optimeringsmodellerna för energi- och effekt möjliggöra ungefär 38 respektive 29% minskning av uppvärmningen, vilket potentiellt kan sänka värmekostnaderna med cirka 46 000 respektive 35 000 svenska kronor. Samma AI -modeller kan minska toppeffekten med cirka 23% beräknad per 24 timmar. Det är värt att notera att den linjära modellen kan marginellt öka FV-behovet något, vilket leder till en ökning av värmekostnaderna. Vidare inkluderar tabellen resultat för de 10 högsta effekttimmar, vilket visar en ökning för den linjära modellen när det gäller toppeffekten, medan AI-modellerna kan minska de högsta topparna med cirka 6%. AI-modellen för optimal värmeeffekt för uppvisar en något högre potential för att kapa toppar, nämligen 7%.


Figur 3 visar tidsserier för både uppmätt och predikterat FV, tillsammans med utomhustemperaturer. Tidsserierna omfattar 24-timmars medelvärden och maximala FV-värden per dygn, tillsammans med 24-timmars medelvärden av utomhustemperaturdata för hela året, samt diagram för de kalla månaderna januari och februari. AI-modellens predikteringar omfattar resultat från när modellen är optimerad för termisk komfort, minskad energianvändning och värmeeffekt. Dessutom tillkommer för jämförelseändamål predikterad resultat från den linjära modellen. Generellt sett är högre toppar märkbara under perioder med lägre utomhustemperaturer, men det framgår att linjära modellen uppvisar störst värmeeffektbehov, följt av uppmätta värden och sedan AI-modellens resultat. Utöver reducerad effekt minskar energianvändningen, vilken motsvarar den totala arean under respektive kurva. Dessutom belyser resultaten den linjära modellens oförmåga att svara på utetemperaturens dynamik, vilket begränsar dess förmåga att justera och prediktera optimal FV-användning.



Tabell 2: Årligt uppmätt och beräknat fjärrvärme (FV) (kWh) och effekttoppar (kWh/h)

	Energi (kWh) eller effekttoppar (kWh/h)	Energi eller effekttoppar per levererad FV (%)
Årlig uppmätta FV, år 2021 (kWh)	233 238	100,0
Årlig FV - linjär modell (kWh)	238 624	102,3
Årlig FV - AI-optimal modell för termisk komfort (kWh)	222 691	95,5
Årlig FV - AI-optimal modell för energi (kWh)	145 364	62,3
Årlig FV - AI-optimal modell för effekt (kWh)	166 517	71,4
Årlig sparad energi (FV) - linjär modell (kWh)	-5 386	-2,3
Årlig sparad energi (FV) - AI-optimal modell för termisk komfort (kWh)	10 547	4,5
Årlig sparad energi (FV) - AI-optimal modell för energi (kWh)	87 874	37,7
Årlig sparad energi (FV) - AI-optimal modell för effekt (kWh)	66 721	28,6
Årlig uppmätta toppeffekt per 24 timmar, år 2021 (kWh/h)	11 963	100,0
Årlig sparad toppeffekt per 24 timmar - linjär modell (kWh/h)	-1 058	-8,8
Årlig sparad toppeffekt per 24 timmar - AI-optimal modell för termisk komfort (kWh/h)	403	3,4
Årlig sparad toppeffekt per 24 timmar - AI-optimal modell för energi (kWh/h)	2 735	22,9
Årlig sparad toppeffekt per 24 timmar - AI-optimal modell för effekt (kWh/h)	2 745	22,9
Topp 10 uppmätta toppeffekt per timme, år 2021 (kWh/h)	76,7	100,0
Topp 10 toppeffekt per timme - linjär modell (kWh/h)	78,7	102,6
Topp 10 toppeffekt per timme - AI-optimal modell för termisk komfort (kWh/h)	72,0	93,9
Topp 10 toppeffekt per timme - AI-optimal modell för energi (kWh/h)	73,0	95,2
Topp 10 toppeffekt per timme - AI-optimal modell för effekt (kWh/h)	71,2	92,9









Figur 3: Till vänster visas 24-timmars genomsnittliga och maximala fjärrvärmeförsörjningsdata, tillsammans med 24-timmars genomsnittlig utomhustemperatur (T_{out}) för hela 2021. Till höger visas figurerna samma data men specifikt för januari och februari.

Byggnads energisignatur

I Figur 4 presenteras energisignaturen för den levererade FV i förhållande till utomhustemperaturen för dygnsmedelvärden under 2021, för de tre optimerade AI-modellerna, uppmätt FV och den linjära modellen.





Figur 4: Energisignaturdiagram för den levererade fjärrvärmens för uppvärmning och varmvatten i den studerade byggnaden. Punkterna representerar levererade FV per dygn och dygnsmedel utetemperaturer under 2021.

De horisontella linjerna som visas i Figur 4 motsvarar det nästan konstanta tappvarmvattenbehovet inklusive VVC-förluster, vilket förblir relativt stabil under året. De sluttande linjerna representerar främst ökande behov av uppvärmning av utrymmen, vilket korrelerar med sjunkande utomhustemperaturer. Särskilt visar AI-modellerna för optimal energianvändning (minimera FV-leveransen) och optimal värmeeffekt betydligt lägre värden, vilket tyder på effektiv reglering av den levererade FV för uppvärmning av utrymmen, i jämförelse med den optimala termiska komfortmodellen. Den optimala termiska komfortmodellen syftar till att prioritera termisk komfort och lägger större vikt vid att bibehålla inomhustemperaturerna nära angivna inställda nivåer, vilket resulterar i mindre potential för energibesparingar med denna modell. I alla fall är resultaten från den linjära modellen närmare de uppmätta data, eftersom den aktuella värmeleveransen bestäms genom en linjär reglerkurva med viss dämpningsförmåga.

Balanstemperaturen (T_b) är i Figur 4 den utetemperatur där lutande linjen skär den horisontella linjen. T_b anger den temperatur vid vilken ingen extern uppvärmningsförsörjning krävs för att upprätthålla termisk komfort inom byggnaden; med andra ord räcker interna värmekällorna för att upprätthålla inomhustemperaturen vid lämpliga nivåer. Resultaten avslöjar att en lägre T_b erhålls från AI-modellen när den optimeras för energianvändning och effektminskning, vilket indikerar större potential för besparingar med dessa modeller i jämförelse med optimering för termisk komfort och den linjära modellen. En lägre balanstemperatur innebär att värme behöver först tillföras vid en lägre utetemperatur, vilket i sin tur resulterar i lägre FV-behov för att upprätthålla inomhustemperaturen inom önskade nivåer.


Bilaga C: Detaljerad kostnadsanalys

Tabell 3: Kostnadsanalys resultat för olika modeller


	FV (faktiskt kostnad baserad på uppmätt FV)	FV-linjär modell	FV för AI-modell för optimal termisk komfort	FV för AI-modell för optimal energianvändning	FV för AI-modell för optimal effekt
K vid -9,8 °C, under måndagen den 2021-12-27	34	33	33	27	32
Kapacitetsavgift (kr)	29 879	29 668	29 568	23 835	28 173
Säsongsuppdelat energipris 2024 (kr)	110 726	111 456	106 076	70 750	80 832
Volymavdrag (kr)	-8 163	-8 163	-8 163	-8 163	-8 163
Totalt (kr)	132 442	132 961	127 481	86 422	100 841
Besparing (% av totalt FV faktiskt kostnad)		-0,4%	3,7%	34,7%	23,9%

Tabell 4: Kostnadsanalys detaljerade beräkningar för olika modeller baserad på [Gävle Energi FV avgifter 2024](#)

Kapacitetspris 2024	
Kapacitetsavgift = K x KP	
K = Kapacitetsbehov vid -10 grader (=24*dygnmedel)	
KP = Kapacitetspris = 37,12 kr/kWh.	37,12
Säsongsuppdelat energipris 2024	
Vinterpris (januari – mars, november – december) 503,4 kr/MWh.	503,4
Vår-/höstpris (april – maj, september – oktober) 431,7 kr/MWh.	431,7
Sommarpris (juni – augusti) 165,2 kr/MWh.	165,2
Volymavdrag 2024	
Om fjärrvärmeförbrukning är större än 100 MWh görs ett avdrag på priset varje månad enligt tabellen nedan.	Prisavdrag
0 – 100	0 kr/MWh
101 – 250	35 kr/MWh
251 – 500	55 kr/MWh



Bilaga D: Graphic User Interface (GUI) till presenterade AI modellen



Graphic User Interface (GUI)

Introduction

This document introduces the Graphic User Interface (GUI) for the developed Python based AI-powered solution for district heating optimization. The software consists of five tabs that are explained in details here.

1-Parameters

The parameters tab shown below enables the user to set different parameters such as path to the training data and model parameters. In this section, you can find a detailed description for each parameter.

The screenshot shows the 'District Heating Optimization' window with the '1-Parameters' tab selected. The interface includes several input fields and buttons for configuring the model and data paths. The 'Models Path' is set to 'data/models/h168-0-p48', 'VAE Model Path' to 'data/models/h168-0-p48/vae-lat5.mdl', and 'Data Path' to 'data/data.csv'. The 'Device' is set to 'cpu'. The 'Number of Models' is 5, 'VAE Latent Size' is 5, and 'VAE beta' is 0.003. The 'Length of History' is 168, 'Length of Missed Data' is 0, and 'Length of Prediction' is 48. A status bar at the bottom shows the following text: 'Datasets are created successfully. Train and test sizes: 1, 0', 'Parameters set', 'Vae model loaded successfully', 'data/models/h168-0-p48/ 1.mdl | 2.mdl | 3.mdl | 4.mdl | 5.mdl | successfully loaded.', 'Optimizer found a solution with costs: [energy: 1098.13, std: 228.80, peak: 33.04]', and 'Deploy results stored at data/deploy_results.csv'. At the bottom of the window are two buttons: 'Set to Default' and 'Save Parameters'.

Tab	Models Path	VAE Model Path	Data Path	Device	Number of Models	VAE Latent Size	VAE beta	Length of History	Length of Missed Data	Length of Prediction
1-Parameters	data/models/h168-0-p48	data/models/h168-0-p48/vae-lat5.mdl	data/data.csv	cpu	5	5	0.003	168	0	48

Set to Default Save Parameters

Models Path: The path to the ensemble of fully trained convolutional neural networks (CNNs). The path should include a number of files with filenames starting from '1.mdl' up to ' N .mdl', where N is the number of models in the ensemble. By default, the software is provided with a number of trained CNN models.

VAE Model Path: The path to the trained variational auto-encoder (VAE) model. By default, the software is provided with a trained VAE model.

Data Path: The path to the training data. The data format should be '.csv', and it should include date, outdoor temperature, indoor temperature, supply temperature, and district heating (dh) columns as shown below. These data serves as the training data to train the model. Also, the data can be used

	A	B	C	D	E
1	date	outdoor	indoor	supply	dh
2	2020-11-18-00	9.3	20.05627082	40.1	20
3	2020-11-18-01	9.2	20.04125369	39.97	21
4	2020-11-18-02	8.8	20.01357823	40.76	24
5	2020-11-18-03	7.6	20.0089603	41.84	25
6	2020-11-18-04	6.8	20.01560362	42.79	25
7	2020-11-18-05	7	20.01968007	43.26	25
8	2020-11-18-06	7	20.03738833	43.66	27
9	2020-11-18-07	6.6	19.95495611	43.97	27
10	2020-11-18-08	8.1	19.94363225	43.67	27
11	2020-11-18-09	9.2	19.976745	43.08	25
12	2020-11-18-10	9.8	20.08366288	41.81	22
13	2020-11-18-11	10.2	20.10159835	40.51	22
14	2020-11-18-12	10.8	20.11726573	40.06	21
15	2020-11-18-13	11.6	20.12501835	39.17	19
16	2020-11-18-14	12.3	20.1233183	38.18	16
17	2020-11-18-15	12.4	20.13737151	36.69	15
18	2020-11-18-16	12.7	20.12128514	35.42	15
19	2020-11-18-17	12.2	20.09582825	34.88	12
20	2020-11-18-18	11.6	20.12897342	34.76	14
21	2020-11-18-19	11.1	20.09166163	35.32	16
22	2020-11-18-20	11.4	20.02904303	36.23	16
23	2020-11-18-21	11.5	20.00299608	36.81	15
24	2020-11-18-22	11.6	19.97238769	36.51	15
25	2020-11-18-23	11.3	19.92888433	36.26	15
26	2020-11-19-00	11.8	19.88661019	36.37	16
27	2020-11-19-01	11.1	19.86672675	36.34	15
28	2020-11-19-02	10.3	19.8543411	35.9	17
29	2020-11-19-03	10	19.82544952	37.33	20
30	2020-11-19-04	10.1	19.81071838	38.53	19
31	2020-11-19-05	10.2	19.79889448	38.76	19
32	2020-11-19-06	9.5	19.79900032	38.93	19
33	2020-11-19-07	9	19.69564252	38.86	24
34	2020-11-19-08	9.3	19.66193278	40.12	24
35	2020-11-19-09	4.7	19.67289262	40.19	24
36	2020-11-19-10	3.1	19.70548254	40.2	31
37	2020-11-19-11	2.8	19.75116222	39.12	49

Device: This is the device used to train the models (the ensemble of CNN models and the cVAE model)

Number of Models: The number of CNN models in the ensemble of models.

VAE Latent Size: The number of dimensions in the latent space of the cVAE model

VAE beta: The β parameter in the cVAE objective function which is used to balance the reconstruction loss against the Kullback-Liber (KL) divergence loss.

Length of History: The number of past hours for which the input data is provided to the model to make prediction about the future. The length of history is denoted by H .

Length of Missed Data: The number of recent hours for which the input data is missing. This feature is used in cases where it is practically impossible to provide the most recent input data to the model. Otherwise, this parameter must be set to zero.

Length of Prediction: The number of future hours for which the model makes prediction.

Set to Default: This button is used to set the parameters to their corresponding default values.


Save Parameters: This button is used to save the current parameters into a file. The saved parameters are restored next time the program is starting.

2-Optimize


The optimization tab is the main tab used to find a sequence of supply temperature values as the control signal to keep the indoor temperature within the comfort range while minimizing some notions of energy consumption.

There are two functionalities implemented in the optimization tab:

1. Optimize: In this case, a random set of the training data is used to analyze the output of the model. Here, the output of the model is compared with two other outputs: (1) the actual data provided by the data (the ground truth), and (2) the output of a piece-wise linear model whose parameters are optimized in another tab (5-Linear Model) described later in this document. The inputs to the optimization problem are stored in an excel file named "optim_inputs.csv", and the outputs of all three options are stored in another excel file named "optim_results.csv". Also, the results are displayed visually by the program as shown in the following figure.



2. Deploy: This mode of operation is used to find an optimal solution in real case scenarios in which only input values are available to the model. The inputs should be provided as an excel file. The program opens the inputs and processes them using the models and provides the optimal outputs both visually and also as an output excel file named "optim_results.csv". An example input excel file accompanies the software at the following directory: "data/deploy_inputs.csv". The following is a snapshot of an example output provided by the deploy functionality:



The followings provide some detailed description about the parameters which can be set in the optimization tab.

Temperature Low: This is the minimum acceptable indoor temperature for the model to produce. Supply temperatures as the output of the optimization process for which the ensemble model predicts lower temperatures than this threshold are discarded by the program.

Temperature High: This is the maximum acceptable indoor temperature for the model to produce. Supply temperatures as the output of the optimization process for which the ensemble model predicts higher temperatures than this threshold are discarded by the program.

Objectives: The objective function is constructed by the weighted sum of three terms which are defined below.

DH sum: This is the weight of the DH sum objective. The DH sum objective is the integral (sum) of the predicted DH values for the prediction horizon.

DH std: This is the weight of the DH std objective. The DH std objective is the standard deviation of predicted DH values across the models in the ensemble averaged over the prediction horizon.

DH max: This is the weight of the DH max objective: The DH max objective is the maximum predicted DH value over the prediction horizon.

Path to Deploy Data: This is the path to find the inputs (data) to the model for the deploy mode.

Path to Save Solution: This is the path to store the solution found by the model at both the deploy and optimization modes.

Optimize: The button to run optimization.

Deploy: The button to run deployment.

3-Train

This tab is used to train the ensemble of CNN models and the cVAE model.

The screenshot shows the '3-Train' tab of the 'District Heating Optimization' application. The interface includes a tab bar at the top with five tabs: '1-Parameters', '2-Optimize', '3-Train' (selected), '4-Prediction', and '5-Linear Model'. Below the tabs, there are input fields for 'Learning Rate' (0.001), 'Number of Epochs' (10000), and 'Batch Size' (500). A 'Path to Save Models' field contains 'data/models/new_models' with an 'Open' button. Below these fields are two buttons: 'Train Models' and 'Train VAE'. At the bottom, there is a status area with text: 'Datasets are created successfully. Train and test sizes: 1, 0', 'Parameters set', 'Vae model loaded successfully', 'data/models/h168-0-p48/ 1.mdl | 2.mdl | 3.mdl | 4.mdl | 5.mdl | successfully loaded.', 'Optimizer found a solution with costs: [energy: 1139.57, std: 189.27, peak: 42.47]', and 'Deploy results stored at data/deploy_results.csv'. At the very bottom are two buttons: 'Set to Default' and 'Save Parameters'.

District Heating Optimization

1-Parameters 2-Optimize 3-Train 4-Prediction 5-Linear Model

Learning Rate: 0.001 Number of Epochs: 10000 Batch Size: 500

Path to Save Models: data/models/new_models Open

Train Models Train VAE

Datasets are created successfully. Train and test sizes: 1, 0
Parameters set
Vae model loaded successfully
data/models/h168-0-p48/ 1.mdl | 2.mdl | 3.mdl | 4.mdl | 5.mdl | successfully loaded.
Optimizer found a solution with costs: [energy: 1139.57, std: 189.27, peak: 42.47]
Deploy results stored at data/deploy_results.csv

Set to Default Save Parameters

Learning Rate: The learning rate which is used by the stochastic gradient descent method to optimize the parameters of the neural networks.

Number of Epochs: The number of epochs to train the parameters of the neural networks. In each epoch, the parameters are updated using the entire data in the training dataset.

Batch Size: The size of batch sampled from the training dataset at every optimization step.


Path to Save Models: The path to save the newly trained models.

Train Models: The button to initiate training of the CNN models. The number of CNNs trained are determined by the size of the ensemble.

Train VAE: The button to initiate training of the cVAE model.

4-Prediction

The prediction tab is used to evaluate the trained models (CNN models) at predicting a sequence of future indoor temperatures provided some inputs. The program also facilitates analyzing sensitivity of the model output w.r.t. each input by increasing and decreasing the input values by some percentages and predicting the outputs of the model. The model predicts three outputs: (1) the output for the original inputs, (2) the output for the increased inputs (displayed by red color), and (3) the output of the decreased inputs (displayed by blue color).



Decrease Supply Temp (%): The percentage to decrease the input supply temperature.

Increase Supply Temp (%): The percentage to increase the input supply temperature.

Decrease Past Indoor Temp (%): The percentage to decrease the past indoor temperature as the input to the model.

Increase Past Indoor Temp (%): The percentage to increase the past indoor temperature as the input to the model.

Decrease Outdoor Temp (%): The percentage to decrease the outdoor temperature as the input to the model.

Increase Outdoor Temp (%): The percentage to Increase the outdoor temperature as the input to the model.

Decrease DH Past (%): The percentage to decrease the past DH as the input to the model.

Increase DH Past (%): The percentage to Increase the past DH as the input to the model.


5-Linear Model

This tab is used to optimize and display a piece-wise linear model used as the baseline for our analysis. The piece-wise linear model relates the outdoor temperature to the delivered DH via the following equation:

$$DH = ReLu(wt + b) + \phi,$$

where, $ReLu(x)$ is equal to x where $x > 0$, and zero elsewhere. t denotes the outdoor temperature, and w, b, ϕ are the weight, bias and offset parameters which are tuned by the optimization process.

The supply temperature is found as a linear function of DH inputs.



Piece-wise linear model parameters:

DH offset: The offset parameter of the piece-wise linear function.

Linear Weight: The weight parameter of the piece-wise linear function.

Linear Bias: The bias parameter of the piece-wise linear function.

Supply Temp Linear Weight: The weight parameter of the linear function.

Linear Bias: The bias of the linear function.

Number of Epochs: The number of epochs to update the parameters of the linear models. In each epoch, all data in the dataset are used.

Display Linear Model: The button is used to display the linear model.

Optimize Linear Model: The button is used to optimize the linear model.