




SmartRenovering

Projekt nr. 2020-06 – afslutningsrapport

Dansk Fjernvarmes F&U konto

Dato: 7. marts 2022

Projektansvarlig

NIRAS A/S

Anders Hahn Kristensen, tlf.: 3078 7555, e-mail: ahk@niras.dk

Medlemsværk

Frederikshavn Forsyning

Claus Flensted Andersen, tlf.: 5163 3142, e-mail: CLFA@forsyningen.dk

Sparringspartner

Aarhus Universitet



FORSYNINGEN



AARHUS
UNIVERSITY

Rev.nr.	Dato	Beskrivelse
1.04	07032022	Endelig version

Udarbejdet af
AHK

Kontrolleret af
ADSB og ELRA

Godkendt af
AHK

Indhold

1	Resumé.....	4
2	Baggrund	4
3	Formål.....	5
4	Metodebeskrivelse	5
5	Dataindsamling	5
6	Dataanalyse	6
6.1	Frederikshavn Forsyning	6
6.2	Fjernvarme Fyn.....	7
6.3	Viborg Varme	8
6.3.1	Datatilpasning brudregistrering	8
6.3.2	Datatilpasning ledningsregistrering	9
7	Machine learning	10
7.1	Data grundlag	10
7.2	Analyse af bruddata	11
7.3	Analyse af Renoveringstilstand.....	12
7.4	Definition af renoveringstilstand	13
7.5	Machine learning model	14
7.5.1	Data til modellen	15
7.5.2	Træning af model.....	16
7.5.3	Evalueret af Model vha. SHAP-values.....	16
7.6	Opsummering af machine learning modellen.....	20
8	Resultater	22
8.1	Forslag til dataregistrering	22
8.1.1	Informationer i ledningsregistrering	22
8.1.2	Informationer i observationer	23
8.2	Sammenhænge	23
9	Konklusion	25
9.1	Perspektivering.....	25

1 Resumé

Hvert år har alle varmeselskaber udsigt til store omkostninger på renovering af deres ledningsnet. Dansk Fjernvarmes F&U-Konto har støttet udviklingen i at undersøge grundlaget for prioriteringen af renoveringsindsatsen for fjernvarmerør med baggrund i et forbedret bud på rørenes fysiske tilstand. Det er projektgruppens tese, at fjernvarmerør til renovering udvælges på et grundlag, som primært baserer sig på driftserfaringer og specifikke termografimålinger.

Ved brug af state-of-the-art metoder inden for data science og machine learning, kortlagte sammenhænge mellem fjernvarme ledningsdata, registrerede utætheder og hændelser.

Der er i samarbejde med Frederikshavn Forsyning indsamlet, undersøgt og samordnet data for eks. rørtyper, isole-ringstyper, varmetab, brud, komponenter, termografi, temperatur, jordtype mm.. Derudover er der benyttet data fra Viborg Varme samt Fjernvarme Fyn. Med data fra de forskellige værker, som er forskellige og har styrker inden for forskellige områder (Forskellige rørsystemer og samlemetoder, forskellig renoveringsstrategi mv.), forelægger der et bredt grundlag for dataanalysen.

Data er analyseret systematisk med henblik på at give et nyt bud på tilstanden af de rørtyper, som generelt er benyttet i Danmark.

Det vises, at machine learning kan anvendes til at forudsige tilstanden af de rørtyper, som er anvendt i Danmark, og at der er et potentiale for anvendelsen af machine learning som et værktøj til renoveringsplanlægning.

Et kritisk punkt i processen for at lave en stabil machine learnings model til renoveringsplanlægning er et solidt data grundlag. Det må derfor konkluderes, at datagrundlaget, som er anvendt i denne undersøgelse, er godt, men at der skal bruges større datagrundlag.

Der opstilles forslag til registrering af data hos forsyningerne, som kan forbedre muligheden for at forudsige og beskrive en udvikling af et rørs fysiske tilstand, øget varmetab og utætheder.

2 Baggrund

Med muligheden for at kende en fjernvarmelednings tilstand bedre og dermed kunne forbedre grundlaget for prioriteringen af renoveringsindsatsen, vil der på sigt være mulighed for at reducere varmetabet hurtigere end ellers, hvilket vil resultere i såvel økonomiske som miljømæssige besparelser.

I forhold til drift- og vedligehold af ledningsnettet vil der desuden kunne opnås en effektiviseringsgevinst, som vil kunne komme fjernvarmeforbrugerne til gavn.

Det har ikke været tradition for at indsamle informationer om brud og øvrige hændelser i fjernvarmenettet, ligesom der heller ikke findes en egentlig ledningsregistreringsstandard, som for vand og spildevand (DANVAND og DAN-DAS). Dette projekt vil derfor bidrage med supplerende bud på, hvilken type data samt detaljeringsniveau for data fjernvarmeforsyningerne med fordel kan begynde at indsamle for at forbedre kendskabet til fjernvarmenettets fysiske tilstand.

Med et øget kendskab til fjernvarmenettets fysiske tilstand vil selskaberne alt andet lige stå stærkere i forhold til en eventuelt kommende benchmarking, hvor der varmeselskaber sammenlignes på forskellige parametre (Fjernvarmepris mv.). Det vil være mere klart hvad der ligger af nuværende og fremtidigeudfordringer og hvilken investeringsindsats der er nødvendig.

Erfaringerne fra projektet vil ud fra en opstilling af sammenhænge mellem forskellige relevante parametre for fjernvarmenettet give fjernvarmeselskaber i Danmark mulighed for at løfte kendskabet til fjernvarmenettet, dens sårbarhed og holdbarhed, på et generelt plan.

3 Formål

Formålet med Projekt nr. 2020-06 fra Dansk Fjernvarmes F&U konto er at undersøge og forbedre grundlaget for prioriteringen af renoveringsindsatsen for fjernvarmerør med baggrund i et forbedret bud på rørenes fysiske tilstand.

Projektgruppens tese er, at udvælgelsen af rør til renovering sker på et grundlag, som primært basere sig på driftserfaringer og specifikke termografimålinger.

Det undersøges i projektet, om udvælgelsen af rør til renovering kan forbedres med en mere systematisk tilgang til data som eks. rørtyper, isoleringstyper, varmetab, brud, komponenter og termografi mm. - og om der ved brug af machine learningsmodeller kan ske en bedre forudsigelse af og fremskrivning af udviklingen på et rørs fysiske tilstand, øget varmetab og utætheder (brud). Dette skal gerne resultere i et forbedret grundlag for at kunne træffe de rigtige beslutninger om investeringerne i ledningsnettet.

4 Metodebeskrivelse

Der er i det følgende benyttet følgende metode:

- Dataindsamling og besøg/interviews med deltagende fjernvarmeselskaber
- Dataanalyse
- Modelkørsler
- Resultater

Først beskrives de efterspurgte data, som forventes nødvendige for det videre arbejde. Derefter er der blevet foretaget en gennemgang af de modtagne data fra de enkelte medvirkende værker.

De modtagne data er herefter blevet tilpasset og analyseret med henblik på det videre arbejde.

Med udgangspunkt i de tilpassede data er machine learningsmodeller blevet udvalgt, og der er udført modelkørsler.

Resultaterne af modelkørslerne er efterfølgende opstillet og kommenteret. Heraf fremkommer analysens konklusioner.

5 Dataindsamling

I forbindelse med dette projekt har der været kontakt til følgende forsyninger: Frederikshavn Forsyning, Fjernvarme Fyn og Viborg Energi. Kontakten byggede umiddelbart på et kendskab fra NIRAS' side til datagrundlaget hos disse forsyninger. Grundet et højt aktivitetsniveau i perioden var det kun Frederikshavn Forsyning, som ønskede at deltage aktivt i dette projekt. Der blev dog givet tilsagn fra hhv. Fjernvarme Fyn og Viborg Energi om at bidrage med udlevering af data som grundlag for projektet.

Generelt for de tre forsyninger var der defineret følgende ønsker til data:

- Udtræk fra ledningsregistrering om hoved- og stikledninger, indeholdende informationer om dimensioner, materialetyper, anlægsår, isolering, fabrikant, alarmtråd mm.
- Udtræk fra ledningsregistreringen om komponenter mm. (fx afgangene, fastspændinger, kompensatorer etc.) med tilsvarende informationer som for ledninger
- Udtræk af registrering af brud og evt. andre hændelser, indeholdende informationer om adresse, hændelsesdata, hændelsestype og årsag, tilhørende de rør eller komponenter som hændelsen er sket på, med oplysning om dimension, materiale, anlægsår, isolering, fabrikant og evt. tilstand.

Ud fra et specifikt kendskab til forsyningerne var der defineret følgende ønsker til data:

Frederikshavn Forsyning:	Resultater fra termografi overflyvning udført i 2020 med drone
Fjernvarme Fyn:	Viden om tilstand for de forskellige rørtyper
Viborg Varme:	Udtræk fra ledningsregistrering men specielt også hændelsesregistreringen, som er meget detaljeret og omfattende.

6 Dataanalyse

I det følgende analyseres data fra de tre forsyninger: Frederikshavn Forsyning, Fjernvarme Fyn og Viborg Energi.

6.1 Frederikshavn Forsyning

Frederikshavn Forsyning har en omfattende lednings- og komponentregistrering, men ingen registrering af data på brudhændelser med position, årstal/dato og årsag.

De udfordringer, som Frederikshavn Forsyning til dagligt står over for, er:

- Gamle stikledninger, der ligger i kasser
- Muffer med o-ringe på grå kapperør
- Kilemuffer

Undergrunden i Frederikshavn er i nogen bestemte områder meget våd, hvorved vandet trænger ind i de ældre udtjente muffer og derved nedbryder rørene.

Øvrige udfordringer er dårligt muffer- og svejsearbejde.

Der er udført termografi-overflyvning med drone i vinteren 2020, og disse data er undersøgt med henblik på eventuel brug i machine learning. Der kunne desværre ikke umiddelbart indsamles data for den udførte termografi-overflyvning. Resultaterne fra termografi-overflyvningen er afleveret som rapporter med adresse og varmetabskarakterer mv., men kunne også ses på et digitalt kort på dronefirmaets hjemmeside. Det var dog ikke muligt at få et udtræk fra det pågældende firma angående de relevante varmetabskarakterer (A-, B- og C-punkter) med information og position for målepunkter med højt varmetab.

Det kunne dertil konstateres, at det kræver en nøje gennemgang og besigtigelse af de udpegede målepunkter med karakter for varmetab, før at de data kan benyttes. En sådan "oprydning" i måledata skal udføres af forsyningen, og dette kunne ikke ske inden for dataindsamlingsperioden.

Nedenfor ses eksempel på visning af termografidata, se Figur 1:



Figur 1: Eksempel på visning med termografi-mosaik som baggrund, ledningsregistrering og "B"-karakter-anmærkninger.

6.2 Fjernvarme Fyn

Fjernvarme Fyn har også en omfattende lednings- og komponentregistrering, men ingen digital registrering af data der fortæller om brudhændelser.

Fjernvarme Fyn har dog et godt kendskab til tilstanden af de forskellige rørtyper i deres ledningsnet. Disse informationer er primært brugt til at give informationer om hvilke parametre, som har indvirkning på den fysiske tilstand af fjernvarmerør.

Overordnet er erfaringerne i forhold til tilstanden:

- Rør fra 1981 og frem er designet med min. 50 års levetid, nok op til 70 år
- Afspærringsventiler bør udskiftes ca. hvert 25 år – korrosion grundet saltholdig vand fra veje
- Stålmuffer har en designet levetid på 25 år
- CO₂ skum-rør har ca. 50 års tilbagebetalingstid mod nye rør. CFC/CP skum kan ikke økonomisk betale sig at renovere ud fra varmetab
- Man skal overveje systematiske muffe-reparationer for fx kilemuffer
- Præisolerede ventiler fra år 2000 og frem - er markant forbedret. Det vurderes stadig, om disse kan holde lige så længe som rørsystemet. Faktisk levetid er uvist
- Man bør lave nogle flere inspektioner i ventilbrønde for at vurdere tilstand
- Kilemuffer forventes at have 25 års levetid, dog ses skader på yngre muffer pga. forkert miljø.

6.3 Viborg Varme

Fra Viborg Varme er der modtaget en omfattende og detaljeret lednings- og komponentregistrering samt en tilsvarende registrering af hændelser. Der blev holdt møde med Viborg Energi for gennemgang af data samt erfaringer om tilstand af ledningsnet og komponenter.

Erfaringerne er:

- I gliderør er der set problemer med, at glidekappen omkring stålrøret har sat sig fast, hvorved de kræfter, som den termiske ekspansion udfører, sætter sig i uønskede områder af rørstrækningen. Systemet er stadig udført med fastspændinger og kompensatorer
- I system 4 ligger hele røret med spændinger. Aksiale kræfter optages i mindre, 20mm, kompensationszoner. Viborg Energi har oplevet brud på disse kompensatorer. Årsagen hertil skønnes, at materialet er blevet udsat for mange termiske cyklusser, eftersom fremløbstemperaturen holdes til et minimum, hvilket medfører, at kompensatoren bliver spændingsfri i perioder
- Muffer: Viborg Energi har benyttet krympemuffer. Der er benyttet faste skaller op til år 2015, hvorefter skumposere er benyttet, som er mere praktiske for at etablere alarmtråde. Alle muffer fremstilles i dag som SX/Multikrymp med dobbelt tætning. Svejsemuffer og krympemuffer anses for "lige dårlige", hvis de ikke er korrekt udført. Fordelen ved løbende vedligeholdelse ved at udskifte gamle muffer er tidligere blevet undersøgt. Det blev vurderet som omkostningstungt, at rør skal blotlægges 2m for ca. hvert 12m. Så det er i stedet prioriteret at etablere nye rør med bedre isolering
- Et brud på en kappe giver typisk et rørbrud inden for 7-10 år
- Alarmtråde har allerede vist deres værd ved både at fange graveskader, før de udvikler sig til regulært rørbrud.
- Ventiler: Viborg Varme er i gang med et vedligeholdelsesprojekt, som efterisolere gamle ventilbrønde samt beskytte mod myrer, der laver sandbunker omkring spindlen, der suger vand. Umiddelbart positive erfaringer om de

nyere præisolerede ventiler. Disse er benyttet fra år 1995 og frem. På ventiler ses korrosionen omkring kraven ved manchetten

- Der ses aldrig brud på lige strækninger, altid i samlinger.

6.3.1 Datatilpasning brudregistrering

Brud på Stik (140 registreringer fra 1999 til 2019) - felter til mulig brug for machine learning og forklaring:

- ST_DN Normstørrelse af stik med fejl
- E_BrudKlas Klassificering af brudskade
- FejType Fejltypekategori
- AlderVBrud Rørets anlægsår, da brud indtræf (skal bruges til beregning af rørets alder ved brud hændelse).
0 her angiver ukendt oprindelig alder
- E_Bruddato År, hvor brud skete
- B_DN_kode Rørkatalog - værdi for ledning med brud. Kun gyldigt for aktuelle brud.
- B_Producen Producent af rør med brud
- B_roertype Rørtype med brud
- E_ID Unkit ID for brud hændelse.
- Join_E_ID Stiklednings ID, hvor brud forekom

Brud på hovedledninger (216 registreringer fra år 1999 til 2019) - felter til mulig brug til machine learning og forklaring:

- HL_DN Normstørrelse af hovedledning med fejl
- E_BrudKlas Klassificering af brudskade
- FejType Fejltypekategori
- AlderVBrud Rørets anlægsår, da brud indtræf (skal bruges til beregning af rørets alder ved brud hændelse)
- E_Bruddato År, hvor brud skete
- B_DN_kode Rørkatalog - værdi for ledning med brud. Kun gyldigt for aktuelle brud.
- B_Producen Producent af rør med brud
- B_roertype Rørtype af røret med brud
- E_ID Unkit ID for brud hændelse
- Join_STREN Hovedlednings ID, hvor brud forekom.

6.3.2 Datatilpasning ledningsregistrering

Hovedledninger til machine learning (3909 ledningsobjekter):

- Rørtype Rørtype
- Producent Producent
- E_Dim_mm Rørnorm diameter
- E_anlag Anlægsår
- E_DN_Kode Lang kategorikode for rørtypen
- LgdHoved Længde af rør
- No_Afgren Antal afgreninger
- No_Aflast Antal aflastninger
- No_Boejn Antal bøjninger

- No_fast Antal fastspændinger
- NO_Komp Antal kompensatorer
- No_Vent Antal afspærringsventiler
- STRENGNR Unik ID for hovedledningen

Stikledninger til machine learning (10525 ledningsobjekter):

- Rørtype Rørtype
- Producent Producent
- E_Dim_mm Rørnorm diameter
- E_anlag Anlægsår
- E_DN_Kode Lang kategorikode for rørtypen
- Længde Længde af rør
- No_Boejn Antal bøjninger
- E_ID Unik ID for stikledningen

De 4 ovennævnte tabeller er benyttet i det videre arbejde med dataanalysen. Nedenfor ses data fra Viborg Varme, se Figur 2:




Figur 2: Hovedledninger med rødt, stik med sort, brud på hovedledninger med røde cirkler, brud på stik med sorte cirkler.

7 Machine learning

7.1 Data grundlag

Viborg Varme har igennem tiden registeret driftsdata som f.eks. brud på ledninger. Årsagen til bruddene er angivet igennem et frit-tekst felt i datasættet. Ved at gennemgå dette felt er der blevet fjernet de brud, som ikke er grundet slid igennem tiden som f.eks. gravearbejde. Herved findes 216, hvor den første er registeret i 1999.

Det antages, at en ledningstilstand bliver værre med tiden. Hvilket tilsyneladende ikke er tilfældet, når vi kigger på brudregistreringer, se Figur 3 nedenfor:



Figur 3: Antal aktive fjernvarmehovedledninger med og uden brud rør, ud fra alderen på rørene.

Figur 3 viser et histogram, hvor antallet af brud er plottet ind i forhold til, hvor længe en ledning har været i produktion. Det første, der kan ses på figuren, er, at de fleste ledninger er mellem 0 og 37 år gamle, og er aldersmæssigt jævnt fordelt.

Herefter observeres et relativt lavt antal brud, når en ledning er under ~15 år gammel. De fleste brud sker, når ledningen er mellem ~15 og 29 år. Efter 29 år falder antallet af brud.

Ved at inspicere nogle enkelte af de registrerede brud fortæller datasættet, at kendskabet til et brud ikke nødvendigvis medfører en renovering. Et eksempel på dette er ledning med ID nr.: 4260.62-2, som har et brud registreret i år 2000, men som enten ikke er blevet rettet i registreringen, da ledningen ikke har registreret nogle renoveringer, eller så er registreringen af arbejdet ikke udført korrekt.

7.2 Analyse af bruddata

Hvis man træner en simpel machine learningsmodel, hvor modellen skal lære de 216 brudobservationer at kende, opnås en model, som korrekt finder 95% af alle brud i datasættet. Problemet med denne model er, at den ikke er følsom over for ledningens alder, dvs. ledningen vil aldrig have risiko for brud, når ledningen ældes. Dette skyldes:

- Lavt antal af brud observationer

- At brud ikke nødvendigvis medfører en renovering
- Manglende korrelation mellem alder og risikoen for brud. Korrelation mellem alder og brud er ikke en nødvendighed, men når datasættet er relativt lille og har usikkerheder i forhold til datakvalitet, kræves dette for at lave en stabil model.

Af disse årsager skiftes målet for analysen og skabelsen af machine learningsmodellen til at være renoveringstilstand baseret på renoveringsregistreringer samt brudhændelserne.


7.3 Analyse af Renoveringstilstand

Ved at skifte målet fra brudhændelser til renoveringstilstand (RT) kan der indhentes mere historisk data for ledningerne. Det skal dog noteres, at årsagen til, at en renovering ikke er angivet, kan skyldes menneskelige fejl som f.eks. skade i forbindelse med gravearbejde.

Renoveringerne fortæller dog, at en ledning godt kan blive udbedret flere gange, før den skiftes helt, samt at nogle få ledninger har op til 3 renoveringsopgaver udført.

Dette skift gør også, at machine learningsmodellen går fra at lære 216 brud at kende til knap ca. 2000 renoveringshændelser,

Nedenfor er der dannet et histogram for renoveringer i forhold til, hvor længe ledningen har været i produktion. Det observeres, at de fleste renoveringer sker, før ledningen er 30 år gammel, og at en eventuel anden renovering sker efter ledningen er blevet 35 år, se Figur 4:



Figur 4: Histogrammer for antal brud i forhold til alder på rør. Første renovering i forhold til alder på rør, 2. og 3. renovering i forhold til alder på rør.

For at udnytte informationen der ligger i antallet af renoveringer udført på en enkelt ledning, skiftes problemstillingen fra at være et binært klassifikationsproblem (brud, ikke brud) til at være et regressionsproblem, hvor vi angiver en renoveringstilstand (RT) for hver ledning baseret på antal af renoveringer samt antallet af brud på ledningen.

7.4 Definition af renoveringstilstand

Renoveringstilstanden (RT) defineres ud fra følgende regler:

- Når en ledning bliver lagt i jorden, har den en RT på 0
- For hver renovering dannes en ny observation for ledningen, og RT værdien stiger med 1

Hvis en renovering medfører anlæggelse af ny ledning:

- Dannes en ny ledning med $RT = 0$
- Den gamle ledning har $RT = 2$
- Hvis en ledning har en brud observation, får $RT + 0.5$

Disse regler betyder:

- $RT = 0$, ledningen i god tilstand
- $RT > 2$, ledning er i dårlig tilstand

Ved at definere problemet som et regressionsproblem, opnås følgende fordele:


- Modellen kan begrænses under træning i forhold til domæne ekspertise:
 - Begrænsningen: RT skal være monoton stigende med alderen.

Begrænsningen medfører, at modellen vi opnår har en dårligere evalueringsscore, men at modellen vil generalisere bedre til det, som vi forventer.

- Der vil kunne påføres andre begrænsninger i forhold til RT, og hvor monoton en input parameter er.
- Der vil ligeledes kunne påføres afhængigheder imellem input parametre i modellen.
- Disse begrænsninger kan kun påføres i regression og binære problemstillinger.

Definitionen af RT medfører, at datasættets størrelse først går fra 3909 til 6330, fordi hver gang der udføres renoveringsarbejde, så medfører det en ny observation. Ved at antage at en ledning har $RT = 0$, når den bliver anlagt, stiger datasættet yderligere til 11709. Her efter fjernes alle ledninger, som ikke har påført renoveringsarbejde, således de kun bidrager med anlæggelses antagelsen. Herved bliver der 6877 datapunkter at træne machine learningsmodellen med.

Ved at plotte RT ind i forhold til år i produktion observeres, at ledninger med en RT på 2 ligger meget spredt ud over intervallet ledningens levetid, men at de fleste ledninger er i dårlig tilstand efter 40 år.



Figur 5: Overblik over sammenhængen mellem renoveringstilstand (RT) og antal år i produktion. Det ses, at hvis RT er 0.0, så er ledningerne generelt set meget nye, og omvendt er der ingen ledninger med en RT på 2,5, som er yngre end 20 år.

7.5 Machine learning model

Når der skal vælges en machine learningsalgoritme er det nødvendigt at vælge en, der passer til problemstillingen og det tilgængelige data.

Når det drejer sig om renoveringstilstand af ledninger, ligger der et implicit krav til modellen. En ledningstilstand må kun blive dårligere over tid, hvilket betyder, at når alderen stiger, skal RT-indekset også stige.

Derudover er datasættet blevet indsamlet over en længere periode, hvor man til start ikke nødvendigvis har haft for øje, hvad det skulle anvendes til. Dette medfører, at der er en vis usikkerhed forbundet med datasættet.

Når datasættet i machine learningskontekst ikke er særligt stort, og derfor ikke har nok observationer til at udbedre disse usikkerheder med, samt at problemstillingen har krav om en forværring af RT over tid, medfører det, at den endelige algoritme skal have mulighed for "monotonic constraints"¹.

Valget af machine learningsmodellen har været drøftet med ekspert fra AU Datalogi (Computer Science).

7.5.1 Data til modellen

Til at træne den endelige model anvendes de nedenstående 15 input parameter samt Renoveringstilstanden (RT), som modellen skal generalisere op i mod, se Figur 6:

¹ <https://xgboost.readthedocs.io/en/latest/tutorials/monotonic.html>

Parameter	Beskrivelse	Parameter type
ANLAGT	Anlæggelsesår	int
ALDER	Alder ved renovering	int
DIM	Dimension	float
ISO	Isolering	float
RORTYPE	Rørtype af: Enkelt, Twin, Flex	binær kategorisering dannelse af 3 nye kolonner int
N_AFGREN	Antal afgrening på ledningen	int
N_AFLAST	Antal af aflastninger på ledningen	int
N_BOEJN	Antal af bøjninger på ledningen	int
N_FAST	Antal af fastspændinger på ledningen	int
N_KOMP	Antal af komponenter på ledningen	int
N_VENT	Antal af ventiler på ledningen	int
DEM	Højde model fra SDFE	float
GV	Grundvands niveau, fra NIRAS	float
VEJKLASSE	Vinter vejrydnings prioritering fra Viborg kommune anvendes som indikator for trafik mængde.	kategoriseres fra 1-3
TSYM	Forsimplet version af GEUS jordarts kort, indeholder: Ler, sand, gytje, andet og BY	binært kategorisering dannelse af 5 nye kolonner int

Figur 6: Input parametre til modellen.

7.5.2 Træning af model

De algoritmer, som er blevet anvendt under træningen af modellen, er alle variationer af "decision tree ensemble" metoder².

Under træningen af hver enkelt algoritme anvendes der en 5 delt krydsvalidering samt optimering af parametre vha. "random grid search". Ved at lave en 5 delt krydsvalidering opnås en mere robust model, som gerne skulle generalisere bedre. Den anvendte "random grid search" metode hjælper med at opnå det bedste resultat ud fra det oplyste datasæt, ved at afdække en bredere del af løsningsrummet.

Problemstillingen er opstillet som et regressionsproblem, derfor anvendes "root mean square" til at evaluere resultatet af hver enkelt model.

Den algoritme som leverede en stabil lav RMS fejl igennem flere modelkørsler er XGBoost³.

Igennem 10 kørsler blev den gennemsnitlige RMS fejl 0.15.

7.5.3 Evaluering af Model vha. SHAP-values

Den endelige model kan evalueres og give indsigt i, hvad modellen har valgt som vigtige parametre. Dette kaldes "Explainable AI", og her er metoden "SHAP-values"⁴ anvendt.

² https://en.wikipedia.org/wiki/Ensemble_learning

<https://scikit-learn.org/stable/modules/ensemble>


³ <https://xgboost.readthedocs.io/en/latest/>

⁴ <https://shap.readthedocs.io/en/latest/index.html>

SHAP-metoden kort forklaret i kontekst af et ledningsnetværk:

1. Vælg en tilfældig ledning, hvor RT er defineret
2. Lad modellen prædiktere RT
3. Ændr en af værdierne for input parametrene og prædikter RT igen.
4. Forsæt denne proces med mange forskellige ændringer og ledninger. Opsummer til sidst hvilken effekt en ændring i f.eks. ALDER har for lednings RT.

På Figur 7 nedenfor er der kørt en SHAP-value analyse for 1000 ledninger.



Figur 7: Et "SHAP summary plot" for de enkelte parametre, der blev brugt til at træne machine learningsmodellen.

På Figur 7 definerer y-aksen en undersøgelse af en enkelt input-feature. Placeringen på x-aksen viser hhv. om ændring i værdi havde a) en positiv effekt, dvs. medførte at den prædikterede RT blev højere, eller b) en negativ effekt, altså medførte en lavere RT værdi.

Farven på hvert enkelt prik på akser angiver om værdien blev ændret til noget højere eller lavere, altså hvad blev alderen ændret til.

Ud fra Figur 7 kan det ses, at ledningens alder har en stor indflydelse på ledningens RT. Ældre ledninger giver en højere RT. For anlæggelsesåret (ANLAGT) ses det modsatte, men en ændring i anlæggelsesår påvirker ikke RT ligeså stærkt som en ændring i alder. Man kan også se, at hvis en ledning er af ISO-materiale, medfører det en lavere RT.


De mest betydende parametre for modellen er ALDEREN, og om ledningen er ENKELT eller der er ISO i materialet.

De enkelte attributter, som modellen har anvendt, kan plottes op mod hinanden, hvilket kan give et lidt større indblik i den ovenstående figur.

Der er blevet udvalgt 3 figurer, hvor ledningens alder er plottet ind overfor en hhv. grundvandsstanden (GV), anlægsåret og snerydningsprioriteringsveje (VEJKLASSE).

I Figur 8 er ledningernes alder plottet ind langs x-aksen, og y-aksen afspejler ændringen i resultatet. Farven på det enkelte datapunkt afspejler, hvor højt grundvandet står ved ledningen. Figuren viser, at ledninger med en relativ lav alder mellem 5-40 år påvirker til en højere RT, hvis grundvandskoten er høj.


En årsag til den dårligere tilstand af ledningerne, når grundvandsstanden ligger højt, kan være, at vandet trænger ind i de ældre udtjente muffe og derved nedbryder rørsystemet. Ledningen kan ligge relativt tæt på grundvandsspejlet og dermed skiftevis ligge hhv. under og over grundvandsspejlet.



Figur 8: Et "SHAP interaction plot", som viser forholdet mellem grundvandsstanden og ledningernes alder.

I Figur 9 repræsenterer farven på højre akse anlægsåret, hvilket man umiddelbart ville tænke er det samme som ledningsalder, men her repræsenterer alderen tidspunktet, hvor ledningen er blevet undersøgt eller udsat for en hændelse samt de ekstra støttepunkter, vi har dannet i det tidligere afsnit.


Her kan der observeres, at der findes en række ledninger, som er lagt i mellem år 1980 og 1990, som øger deres sandsynlighed for at have en bedre tilstand og en lavere renoveringstilstandsværdi end andre ledninger, som er blevet observeret ved samme alder.



Figur 9: Et "SHAP interaction plot" som viser forholdet mellem ledningens anlægsår og alder.

I Figur 10 undersøges snerydningsprioriteringsvejes effekt på renoveringstilstanden. Denne feature bliver anvendt som en proxy for trafikbelastning i form af at en højprioritering (vejklasse=0) og indikerer, at vejen har meget trafik og derfor ryddes først for sne - hvorfra de tre prioriteringskategorier afspejler værdierne 0, 1 og 2.

Fra figuren observeres, at veje, som har høj prioritering (kategori 0) og herved antaget mere trafik, øger sandsynligheden for, at en lednings tilstand er dårligere, end en ledning som ligger i kategori 1 eller 2.



Figur 10: Et "SHAP interaction plot" som viser forholdet mellem vejklasse og alder.

7.6 Opsummering af machine learning modellen

Den ovenstående undersøgelse af machine learning, anvendt til at forudsige rørenes tilstand i fjernvarmenettet, viser, at der er et potentiale for anvendelsen af machine learning som et værktøj til renoveringsplanlægning. Ud fra SHAP analyserne kan man se, at der er overensstemmelse mellem de parametre, som forventes at have indflydelse på RT, og de parametre, som faktisk har indflydelse på RT i machine learningsmodellen.


Et kritisk punkt i processen for at lave en stabil machine learningsmodel til renoveringsplanlægning er et solidt data grundlag.

For det indeværende datasæt er der kun registreret data, når der bliver gravet, og når der er et brud på en ledning, som skal udskiftes eller repareres. Dette giver derfor kun data, der beskriver, når ledningerne er i stykker. Der mangler altså data, der beskriver ledninger, som er i god stand. Det er derfor også nødvendigt at registrere data, når man har gravet og finder ud af, at der ikke er et brud på ledningen.


Datagrundlaget, som er anvendt i denne undersøgelse, er noget af det bedre, hvad angår fjernvarmedata. Datakvaliteten af dette datasæt har igennem dialog med domæne-folk samt en ordentlig datavask blevet gjort tilfredsstillende til at bruge til machine learning. Derfor anbefales det, at såfremt det ønskes at arbejde videre med machine learning igennem driftsdata, skal der fastsættes standarder. Standarderne skal omfatte både indsamling og dataformater til lagring af driftsdata.

Ved at gøre dette vil man kunne opnå en model, som kan anvendes i et beslutningsstøttværktøj, som eksemplerne viser nedenfor på Figur 11 og Figur 12. Værktøjet vil kunne inkorporere fremskrivning af varmetabet i ledningerne, renoveringstilstand (machine learningsmodel) samt andre domæne vigtige parametre. Her vil en fagekspert kombinere

sin domæne-viden sammen med en data-drevet tilgang for at danne en endnu mere effektiv renoveringsplanlægning.



Figur 11: Tilstanden af Viborg Varmes ledningsnet i år 2020.



Figur 12: Tilstanden af Viborg Varmes ledningsnet i år 2025.

8 Resultater

I dette projekt er formålet at undersøge og løfte kendskabet til fjernvarmenettet for dermed at være i stand til at prioritere og udvælge de rigtige renoveringsprojekter, i den rigtige rækkefølge og med det optimale årlige budget for at kunne vedligeholde og udbygge nettet. Altså "SmartRenovering".

Erfaringerne fra de medvirkende selskaber om tilstanden af ledningsnettet er mange, men også forskellige. Det viser, hvor afhængigt nettets tilstand for enkelt selskab er af brugen af rør- og komponent fabrikater, typer, metoder mv. gennem tiden. Og hvor vigtigt det således er at have et solidt kendskab til alt dette.

De gode erfaringer er ikke nødvendigvis bakket op af graden af registrering af relevante parametre, som kan give yderligere og mere detaljerede informationer om tilstanden af ledningsnettet. Det være sig i forhold til ledningsregistreringen, men også i forhold til observationer, som brud mv, på ledningsnettet, som gøres hver dag.

Data fra Viborg Varme er "trænet" med machine learningsmodeller, som beskrevet ovenfor. Resultaterne viser, at der kan eftervises nogle allerede kendte sammenhænge, og at der er et potentiale for at arbejde videre med machine learning. Det vil dog være nødvendigt med mere data og fra flere selskaber. Og data skal være registreret mere metodisk med flere input. Først derefter kan der arbejdes videre med machine learningsmodeller med flere iterationer.

Nedenfor er der som resultatet på dette projekt opstillet dels et forslag på vigtige informationer og parametre, som bør registreres hos selskaberne, og dels et katalog med sammenhænge mellem de relevante parametre, som kan give alle fjernvarmeselskaberne i Danmark mulighed for at øge kendskabet til deres fjernvarmenet.

8.1 Forslag til dataregistrering

Nedenfor er der ud fra erfaringer fra dette projekt opstillet forslag til registrering. Forslaget er delt i 2:

1. Registrering af ledninger (linjer) og komponenter (punkter)
2. Registrering af observationer (punkter).

Nedenstående forslag til registrering skal ses som et supplement til ledningsregistreringen. Der er kun anført nødvendige informationer i forhold til arbejdet med at kende tilstanden bedre.

8.1.1 Informationer i ledningsregistrering

Ledninger:

Parameter	Beskrivelse
Ledningskategori	Transmission, hoved eller stik
Anlægsår	Årstal
Rørtype	Beton, Enkelt, Twin, AluFlex, CuFlex, PEXFlex, Ukendt, TwinAluFlex, System4, Glide, Stål Fast m. fl
Producent	Logstor, StarPipe, Ukendt, IsoPlus, Tarco, ICM, Dürotan, ISO m. fl
Dimension	Rørnorm diameter i mm
Alarm_aktiveret	Med eller uden alarmsystem og om aktiveret
Befæstning	Land, by, city
Isolering	Serie 1, 2 eller 3

Komponenter:

Parameter	Beskrivelse
Komponenttype	Ventil, omløb, bøjning, fastspænding, kompensator m. fl
Anlægsår	Årstal
RørID	ID til ledning og hermed kan alle info på ledning sammensættes til komponentet
Producent	Logstor, StarPipe, Ukendt, IsoPlus, Tarco, ICM, Dürotan, ISO m. fl
Dimension	Norm diameter i mm
Alarm_aktiveret	Med eller uden alarmsystem og om aktiveret
Befæstning	Land, by, city
Isolering	Serie 1, 2 eller 3

8.1.2 Informationer i observationer

Observationer:

Parameter	Beskrivelse
Observationstype	Brud, termografi, opgravning m.fl.
Dato	Dato
Rør eller komponentID	ID til ledning eller komponent. Hermed kan alle info overføres til observationen, så info kan gemmes, hvis ledning eller komponent skiftes
Status	Aktiv eller historisk, alt efter om ledning eller komponent, som observationen er tilknyttet fortsat er i drift
Type	Svejsning er utæt, Lodning er utæt, Preskobling er utæt, Armatur er utæt
Metode	Fly, drone, termografi, tlf., andet
Årsag	Udvendig tæring, knækket, revnet, korrosion,
Befæstning	Asfalt, Rabat, have, fortov, land
Tilstand	Ledning eller komponent, som ny, tæret, korrosion indvendigt eller udvendigt
Forløb varighed	Varighed timer
Forløb aflukning	Antal installationer aflukket

8.2 Sammenhænge

Nedenstående katalog er en oversigt over sammenhænge ud fra selskabernes erfaringer og ud fra analysen med machine learning og renoveringstilstanden i forhold til de forskellige parametre.

Parameter	Beskrivelse	Sammenhænge
ALDER	Alder ved renoveringshændelse	I machine learningsmodellen observeres det, at der findes en række ledninger, som er anlagt i mellem år 1980 og 1990, som øger deres sandsynlighed for at have en bedre tilstand end andre ledninger, som er blevet observeret ved samme alder. Dette stemmer overens med Fjernvarme Fyns erfaringer om, at rør fra år 1981 og frem er designet med min. 50 års levetid, nok op til 70 år.
ENKELT	Rørtype	Machine learningsmodellen har kraftige signaler for renoveringstilstanden (RT), hvis røret er af typen Enkelt. Det giver god mening i forhold til erfaringerne fra selskaberne om udfordringer med rør og komponenter fra den periode, hvor enkeltrør blev anlagt.

ISO	Isoleringsserie	Machine learningsmodellen viser også markante signaler for renoveringstilstanden (RT) i forhold til isoleringsserie 1, 2 eller 3. Sammenhængene er ikke undersøgt nærmere, men det stemmer godt overens med selskabernes erfaringer med rør fra de forskellige generationer og isoleringsserier.
FAST	Antal af fastspændinger på ledningen	Der er fundet sammenhænge i modellerne mellem rør med højt antal fastspændinger og renoveringstilstanden. Det stemmer umiddelbart godt overens med Viborg Varmes udfordringer med gliderør.
KOMP	Antal af komponenter på ledningen	Der er i machine learningsmodellen fundet sammenhænge mellem stort antal komponenter og renoveringstilstanden. Sammenhængene er ikke undersøgt nærmere, men det stemmer overens med samtlige medvirkende selskabernes erfaringer med rør og komponenter fra de forskellige generationer af rør og rørsystemer.
GV	Grundvandsniveau	I machine learning modellen observeres det, at ledninger med en relativ lav alder mellem 5-40 år påvirker til højere RT, hvis grundvandskoten er høj. Dette stemmer overens med Frederikshavn Forsynings erfaringer om, at der i meget våde områder trænger vand ind i de ældre udtjente muffe og derved nedbryder rørsystemet.
VEJKLASSE	Snerydningsprioritierungsveje	I machine learningsmodellen observeres det, at veje som har høj prioritering (kategori 0), og herved antaget mere trafik øger sandsynligheden for at en lednings tilstand er dårligere, end en ledning som ligger i kategori 1 eller 2.

9 Konklusion

Der er med Projekt nr. 2020-06 fra Dansk Fjernvarmes F&U konto arbejdet med muligheden for at forbedre grundlaget for prioriteringen af renoveringsindsatsen for fjernvarmerør med baggrund i et forbedret bud på rørenes fysiske tilstand.

Projektet er fuldført i et samarbejde NIRAS og Frederikshavn Forsyning. Viborg Varme og Fjernvarme Fyn har bidraget med yderligere data og erfaringer omkring fjernvarmenettets tilstand.

Forskellige typer data og informationer om fjernvarmenettets tilstand fra de medvirkende varmeselskaber har været indsamlet og undersøgt. Det er i den forbindelse konstateret, at der er stor erfaring med fjernvarmenettets tilstand, som er afdækket via besøg og interviews. I forhold til data som kan underbygge erfaringsgrundlaget omkring fjernvarmenettets tilstand, kan det fastslås, at det overordnet set ikke understøttes af registrerede data. Kun ved Viborg Varme er der systematisk registreret observationer og hændelser for fjernvarmenettet siden år 1999, som kan benyttes til undersøge rørenes fysiske tilstand på nye måder. I det videre forløb er det data fra Viborg Varme, som er benyttet.

Data er samordnet og analyseret systematisk. Ved brug af nyeste metoder indenfor data science og machine learning er der analyseret data for at kortlægge sammenhænge mellem data og registrerede observationer med henblik på at kunne give et nyt bud på tilstanden af de rørtyper, som generelt er benyttet i Danmark.

Det kan indenfor dette projekts rammer konkluderes at:

1. Der er "signal" - eller sammenhænge - i de data der er undersøgt med machine learning. De benyttede modeller kan bruges til at undersøge fjernvarmenettets fysiske tilstand og til at forudsige og fremskrive en udvikling af den fysiske tilstand, varmetab og utætheder. Det vil dog kræve, at der arbejdes med flere data, og at der udføres flere iterationer på datasættet. Der er i dette projekt udført en iteration med de udvalgte machine learningsmodeller.
2. Der mangler flere data fra flere fjernvarmeselskaber til at arbejde videre med machine learning. Det aktuelle fokus på digitalisering for at effektivisere drift og renovering yderligere kan være en driver for at få indsamlingen af data og observationer højere på selskabernes dagsorden.

Der er i dette projekt opstillet forslag til hvilke data, der bør indsamles for at kunne bidrage til yderligere fjernvarmenettets tilstand. Der er yderligere opstillet en let tilgængelig oversigt, som viser, hvor branchen vil kunne tilgå de nye indsigter omkring sammenhænge i f.eks. rørs alder og fysiske miljø.

9.1 Perspektivering

Med en fremtidig koordineret dataindsamling omkring fjernvarmenettet og observationer på nettet ud fra en fælles datastruktur vil der være mulighed for at fortsætte arbejdet med at få indsigt i fjernvarmerørs tilstand og dermed kunne forbedre grundlaget for prioriteringen af renoveringsindsatsen. Der vil dermed på sigt være mulighed for at reducere varmetabet hurtigere og bedre undgå brud end ellers, hvilket vil give såvel økonomiske som miljømæssige besparelser.

Der kan være andre fjernvarmeselskaber med detaljerede data som Viborg varme, som vil gøre det muligt at fortsætte machine learning på et bredere datagrundlag.

Yderligere er der kendskab til, at en større producent af fjernvarmerør har arbejdet med tilsvarende metoder. En koordineret indsats med dette selskab omkring data, datas sammenhænge og brug af data science modeller kunne forbedre mulighederne for at opnå en større og mere detaljeret indsigt i fjernvarmenettets tilstand.

Sidst, men ikke mindst, kan det undersøges, om der er udført computer vision machine learning på termografi-billederne. Det vil kræve data at "lære" på, og dermed igen registrering af observationer fundet med termografering. Men det vil kunne bidrage til en mere præcis afrapportering af termografi-overflyvninger, og samtidig give et helt unikt bidrag til at opnå kendskab til fjernvarmenettets tilstand.