

En AI-modell för vattenledningsnätet

Test av möjligheter med riskstyrning av underhåll och planeringsverksamhet.

Tillsammans för världens
mest hållbara stad



STOCKHOLM
VATTEN
OCH AVFALL

Rapport

Diarienummer
19MB262

Projektnummer
9005460

En AI-modell för vattenledningsnätet

Test av möjligheter med riskstyrning av underhåll och planeringsverksamhet.

David Rehn
2019-04-01

© Stockholm Vatten och Avfall 2019

Författare: David Rehn

Kontaktuppgifter: Stockholm Vatten och Avfall, 106 36 Stockholm

Telefon: 08-522 120 00

Webb: www.svoa.se

Sammanfattning

Med AI-tekniken kan SVOA göra bättre antaganden om vilka problemområden och ledningar som har en större risk för att drabbas av läckor. Användningsområdet är framförallt inom förebyggande underhåll (FU) där aktiv läcksökning kan styras mot områden med höga risktal. Resultaten hittills är mycket trovärdiga och ytterligare verifiering kommer att ske av fler va-organisationer. Tekniken bör även kunna tillämpas inom fler områden, exempelvis prediktion av risker inom avloppsledningsnätet baserat på resultat från TV-inspektioner eller förutsägelse av produktionsbehov av dricksvatten.

Författaren rekommenderar att SVOA implementerar AI-funktionalitet för riskberäkningar inom vattenledningsnätet i sin dagliga verksamhet, och att sonderingar görs kring möjligheter att utveckla ett professionellt verktyg.

INNEHÅLLSFÖRTECKNING

1. Inledning	3
2. Problemformulering och syfte	4
3. Metod	5
3.1. Vad är AI	5
3.2. Hur fungerar denna AI-modell	5
3.3. Tillvägagångssätt	6
4. Resultat och analys	8
4.1. AI-tekniken	8
4.1.1. AI	8
4.1.2. Diskussion	8
4.1.3. Konditionsvärden	9
4.2. VA-teknik	10
4.2.1. Fakta kring vattenledningsnätet	10
4.2.2. Indelning av vattenledningsnätet	11
4.2.3. Utvärdering av ett VA-ledningsnät	12
4.3. Resultat från AI-beräkningen	13
4.3.1. Fördelning av konditionsvärdet	13
4.3.2. Konditionsvärde och material samt byggår	14
4.3.3. Extra högt konditionsvärde och material samt byggår	14
4.3.4. Kumulativ distribution av konditionsvärden per material	15
4.3.5. Riskområden	17
4.3.6. Specifika ledningar med ett högre konditionsvärde	18
4.3.7. Läckor 2018	19
5. Diskussion	20
5.1.1. Diskussion	20
5.1.2. Fortsatt arbete	20
6. Slutsatser och rekommendationer	21
7. Referenser	22

1. Inledning

Smarta städer och IoT-teknik är högt på dagordningen inom många verksamheter. Stockholms stad har som målsättning att vara världens smartaste stad år 2040, och driver bl.a. projektet Digital Demo Stockholm (DDS) för att utveckla goda exempel inom ämnesområdet.

Även inom vatten- och avloppsbranschen finns många idéer och tankar om hur teknik kan utvecklas. Stockholm Vatten och Avfall (SVOA) medverkar exempelvis i DDS, med projekt rörande vattenläckage och vattenkvalitetsmätningar. Denna studie redovisar resultat från en prototyp vad gäller artificiell intelligens (AI) och artificiella neurala nätverk (ANN). Arbetet har genomförts vid enheten ledningsnät utredning och utveckling (LU). Delkapitel 4.2 har skrivits av Tommy Giertz (PSP), där han har bidragit med VA-tekniska erfarenheter.

Stockholm 2019-04-01

David Rehn

2. Problemformulering och syfte

AI-tekniken kan ge SVOA stora möjligheter att snabbt bearbeta och analysera stora mängder data, och därefter med resultaten styra eller utvärdera verksamheter. I detta projekt har en AI-modell tagits fram med målet att statusbedöma vattenledningar (och därmed även förutspå vattenläckor). I denna rapport beskrivs och utvärderas dels AI-tekniken som sådan, men även resultatet av AI-beräkningarna ur ett va-tekniskt perspektiv. Målsättningen med AI-beräkningen i detta pilotprojekt är inte att ta fram en slutgiltig planeringsmodell eller liknande, utan att i ett testprojekt utvärdera teknikens precision och lämplighet.

3. Metod

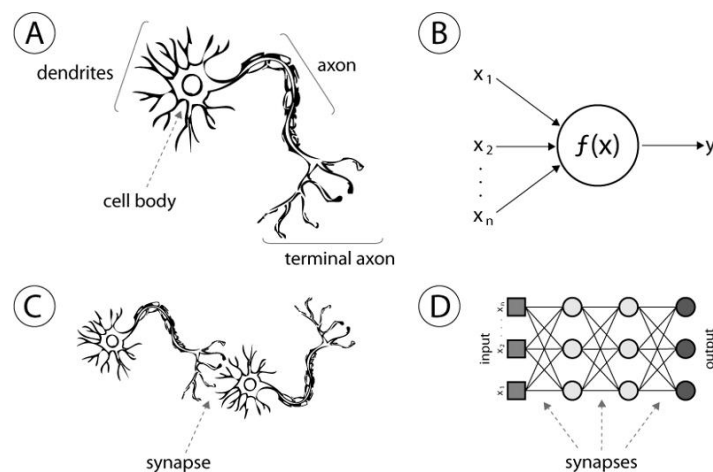
3.1. Vad är AI

”Artificiell intelligens” är ett vittomfattande begrepp som syftar till att beskriva intelligens som uppvisas av datorer (till skillnad från ”naturlig intelligens” i djur- och människoriket). Flertalet intelligenta metoder för maskininlärning ingår här, vilka bearbetar stora datavolymer, hittar mönster och fattar beslut.

3.2. Hur fungerar denna AI-modell

Artificiella neurala nätverk (ANN) är en typ av maskininlärningsalgoritm som utformats med syftet att programmatiskt efterlikna den mänskliga hjärnans signalsystem (biologiska neurala nätverk). Tekniken utvecklades redan 1943 av Warren McCulloch och Walter Pitts (Maltarollo et al. 2013), men har först på senare år kunnat tillämpas mer storskaligt pga. medföljande krav avseende datalagrings- och beräkningskapacitet. Utvecklingen har gått fort och de neurala nätverken utgör idag stommen i merparten av de sofistikerade AI-system som börjar ta allt mer utrymme i vår värld.

Konceptuellt utgörs ett ANN, likt dess biologiska motpart, av *neuroner* (nervceller) som är sammankopplade i olika *lager* med *in/utgångar* (dendriter/axon). Information (numerisk indata) tilldelas vikter och flödar genom dessa neuroner/lager, där matematisk bearbetning (dels *summation* av viktad indata, och dels en *transferfunktion* där summan av indata förstärks eller försvagas) genomförs innan den till slut når ett *utdatalager* och, i en *aktiveringsfunktion*, transformeras till ett värde inom ett förvalt klassificeringsintervall.




Figur 1. A: Biologisk neuron med dendriter/axon B: Viktad indata genomgår matematisk bearbetning i artificiell neuron C: Biologiska neuroner sammankopplas och överför information i synapser D: Konceptuell utformning av ANN med indata, neuroner/lager och utdata (Maltarollo et al. 2013)

Differensen mellan beräknad utdata-klassificering (t.ex. ett värde mellan 0 och 1 i en binär klassificering) för varje ingående objekt och de historiskt kända värden (0 eller 1) som modellen avser att konvergera mot beräknas mha. en *förlustfunktion*. Den beräknade ”förlusten” förs därefter in i en optimeringsalgoritm som iterativt beräknar om vikterna och successivt för modellens precision mot sitt maximum (där så många beräknade utdatavärden/objekt som möjligt stämmer överens med deras historiskt kända motparter). När detta maximum är nått är modellen färdigtränad.

3.3. Tillvägagångssätt

En konventionell arbetsprocess för utformande av ANN presenteras i flödesschemat nedan.



Figur 2. Arbetsprocess för utformning av ANN

På Stockholm Vatten och Avfall har ett djupt (multipla lager) ANN utformats, tränats och testats enligt denna process, med syfte att konditionsklassificera vattenledningar. Programmeringsspråket Python användes under hela arbetsprocessen, där merparten av den geospaciala databearbetningen gjordes med modulen GDAL och utformningen av ANN med Keras.

Flertalet litterära och muntliga källor inom och utanför verksamheten bidrog till konkretisering av totalt 21 indataparametrar vilka dels utgör ledningarnas tillhörande attribut (material, dimension, ålder etc.) och dels övriga (externa) parametrar med eventuell påverkan på vattenledningars kondition (geologi, väder, driftstörningar etc.). Utdata är historisk läcka/förnyelse (registrerade arbetsorder samt omlagda ledningar) och total datamängd uppgår till ca. 37 000 ledningsobjekt. Allt har strukturerats och lagrats i en PostgreSQL-databas enligt exemplet nedan (med vissa förändringar för möjliggörande av matematisk analys).

Tabell 1. Exempel på datastruktur

OBJEKTID	Material	Dimension	Ålder	Tryckzon	Geologi	Läcka
1	Grå	150	87	Normal	Morän	Ja
2	Grå	150	66	Normal	Morän	Nej
3	Seg	100	34	Hög	Lera/Silt	Nej
4	PE	160	16	Normal	Berg	Nej
5	Asb	200	53	Reducerad	Sand	Ja

Alla 21 medverkande in/utdataparametrar med tillhörande källor, format och bearbetningsmetoder presenteras i tabellen nedan.

Tabell 2. In/utdata samt bearbetningsmetodik

Indataparameter	Källa	Format	Bearbetning	Lagring
Tryckzon	Intern GIS	Shape	Python/GDAL	PostgreSQL
Renovering	Intern GIS	Shape	Python/GDAL	PostgreSQL
Korrosionsskydd	Intern GIS	Shape	Python/GDAL	PostgreSQL
Anläggningsår	Intern GIS	Shape	Python/GDAL	PostgreSQL
Ålder	Intern GIS	Shape	Python/GDAL	PostgreSQL
Material	Intern GIS	Shape	Python/GDAL	PostgreSQL
Dimension	Intern GIS	Shape	Python/GDAL	PostgreSQL
Järnväg	Open Sthlm	Shape	Python/GDAL	PostgreSQL
Befolkningsändring	SCB	Excel	Python/pandas/GDAL	PostgreSQL
Driftstörningar	Intern GIS	Shape	Python/GDAL	PostgreSQL
Serviskoppling	Intern GIS	Shape	Python/GDAL	PostgreSQL
Dimensionsändring	Intern GIS	Shape	Python/GDAL	PostgreSQL
Avstånd t. huvudl.	Intern GIS	Shape	Python/GDAL	PostgreSQL
Brandpostkoppling	Intern GIS	Shape	Python/GDAL	PostgreSQL
Ventilkoppling	Intern GIS	Shape	Python/GDAL	PostgreSQL
Höjd	Intern GIS	Shape	Python/GDAL	PostgreSQL
Markkaraktär	Open Sthlm	Shape	Python/GDAL	PostgreSQL
Bebyggelse	Open Sthlm	Shape	Python/GDAL	PostgreSQL
Trafiklast	Trafikkontoret	API/JSON	Python/requests/json/GDAL	PostgreSQL
Meteorologi	SMHI	API/CSV	Python/requests/csv/GDAL	PostgreSQL
Geologi	SGU	Shape	Python/GDAL	PostgreSQL


Utdataparameter	Källa	Format	Bearbetning	Lagring
Läckage/förnyelse	Intern GIS	Shape	Python/GDAL	PostgreSQL

4. Resultat och analys

4.1. AI-tekniken

4.1.1. AI

Under träningskedet delades datamängden in i två delar, där 80 % användes för träning och 20 % för test/validering. Efter ca. 1000 iterationer nåddes ett stabilt maximum för precisionen (och minimum för förlusten). Statistik och resultat presenteras nedan.



Figur 3. Iterativ precisions- och förlustutveckling för tränings- (blå) och testdatamängd (orange)

Tabell 4. Statistik och resultat (träning)

Antal ledningsobjekt	Läcka	Inte läcka	Precision
39910	6049	33861	92,60 %

4.1.2. Diskussion

Genom att studera de två grafer som visualiserar precisions- respektive förlustutveckling, blir det tydligt att relativt stora förändringar uppnås under de första 100 iterationerna, innan kurvan ”planar ut” något. Detta beror på en successiv minskning av *steglängden* (eng. *learning rate*), dvs. den faktor som avgör hur stora viktskillnader som beräknas mellan iterationerna.

Modellen lär sig iterativt hur parametrarna påverkar ledningarnas kondition och justerar vikterna för snabbare konvergens. Lagerstrukturen möjliggör även beräkning av hur parametrarna påverkar varandra (hur olika parameterkombinationer påverkar konditionen), vilket inte bara reflekterar verkligheten, utan markant skiljer sig gentemot andra maskininlärningsmetoder som ofta (inte alltid) baseras på linjär regression där varje parameter tilldelas en enskild vikt.

Den slutliga precisionen (92,60 %) visar hur stor andel ledningsobjekt som, enligt modellens beräkningar, har binära värden (beräknat värde > 0,5 anses motsvara 1 och värden < 0,5 anses motsvara 0) som stämmer överens med de historiska värdena. Detta visar att modellen är robust och att den haft en mycket god inlärningsförmåga. Samtidigt berättar den dock inte hela sanningen,

eftersom ett okänt antal ledningsobjekt är felklassificerade (oupptäckt läckage). För att bilda en uppfattning om modellens faktiska precision krävs följaktligen ytterligare verifieringssteg.

4.1.3. Konditionsvärden

Sannolikhetsvärdet som beräknas av modellen beskriver sannolikheten att ledningsobjekt tillhör klass 1 (dvs. ledningar med tidigare läckage el. ”problem”). Av denna anledning är det rimligt att betrakta detta värde som en indikation på ledningens kondition, ett ”konditionsvärde”, där ledningar med värden nära 0 kan anses ha ”god kondition”, eftersom ledningar med liknande attribut i princip varit historiskt ”problemfria” (dvs. utan inrapporterat läckage). På samma vis är ledningar med, av modellen beräknade, konditionsvärden över 0,5 ledningar vars attribut mer liknar ledningar med dålig kondition (dvs. ledningar med rapporterat läckage) än ledningar med god kondition (dvs. ledningar utan rapporterat läckage). Därav kan slutsatsen dras att dessa ledningar inte har ”god kondition”, vilket innebär en viss ”risk för läckage” (en risk som ökar i takt med konditionsvärdet). Därför tilldelas de epitetet ”riskledningar”.

Bland riskledningarna finns en mindre mängd ledningar med förhöjd risk. Denna subkategori tilldelas epitetet ”högriskledningar”, och deriveras statistiskt. Mer konkret är högriskledningar ledningar med statistiskt avvikande konditionsvärden, vilka överstiger summan av medelvärdet och standardavvikelsen i riskledningsfördelningen.

En sammanställning av olika konditionsvärdesintervall (konditionsvärde, K) med innebörd presenteras nedan.

God (till relativt god) kondition: $0 \leq K \leq 0,5$

Risk: $0,5 < K \leq 1$

Hög risk: $\text{medelvärde}_{\text{RL}} + \text{standardavvikelse}_{\text{RL}} = \mu + \sigma = \frac{1}{N} \sum_{i=1}^N x_i + \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2} < K \leq 1$

För SVOA gäller följande:

$\text{medelvärde}_{\text{RL}} = \mu = 0,78$

$\text{standardavvikelse}_{\text{RL}} = \sigma = 0,13$

$K_{\text{HRL}} > 0,91$

Vid tillämpning av färdigtränad modell på aktuellt vattenledningsnät i Stockholms kommun identifierades totalt 7890 riskledningar, varav 1016 högriskledningar. Dessa presenteras nedan.

Tabell 5. Nyckeltal


Antal ledningsobjekt	Risk	Hög risk	μ (medelvärde)	σ (standardavvikelse)
37910	7890	1016	0,193	0,319

4.2. VA-teknik

Delkapitelförfattare: Tommy Giertz

4.2.1. Fakta kring vattenledningsnätet


Ledningsnätet för vatten är i dagsläget ca 1800 km långt och de vanligaste materialen är i huvudsak gråjärn (882 km), segjärn (487 km) och PE (377 km). Under åren har givetvis material och skarvtyper förändrats och utvecklats. Även produktionsmetoder varierar, vilket kan ge såväl positiva som negativa konsekvenser vad gäller en lednings tekniska livslängd.



Figur 4. Fördelning av material i ledningsnätet, blå=gråjärn 43%, beige=segjärn 32%, grön=PE 23%, röd=övrigt 2%.

Utöver SVOAs ledningsnät står den enskilde kunden för en stor del av de markförlagda vattenledningarna.

I bilden nedan ser vi fördelningen av befintliga ledningar vad gäller de olika materialen och dess längd fördelat per byggår. Eftersom material och skarvtyper har förändrats över tiden är vissa material uppdelade i flera kategorier. Vi ser även mer ovanliga ledningsmaterial som koppar och PVC-rör, samt renoverade rör.



Figur 5. Fördelning av ledningslängd per material och byggår (t.o.m. 2006).

De äldsta ledningarna i drift är alltså från 1865 och vi ser även att vi haft tre större utbyggnadsperioder av vattenledningsnätet:

1 ca 1930 till 1939

2 ca 1950 till 1970

3 ca 1995 till 2005.

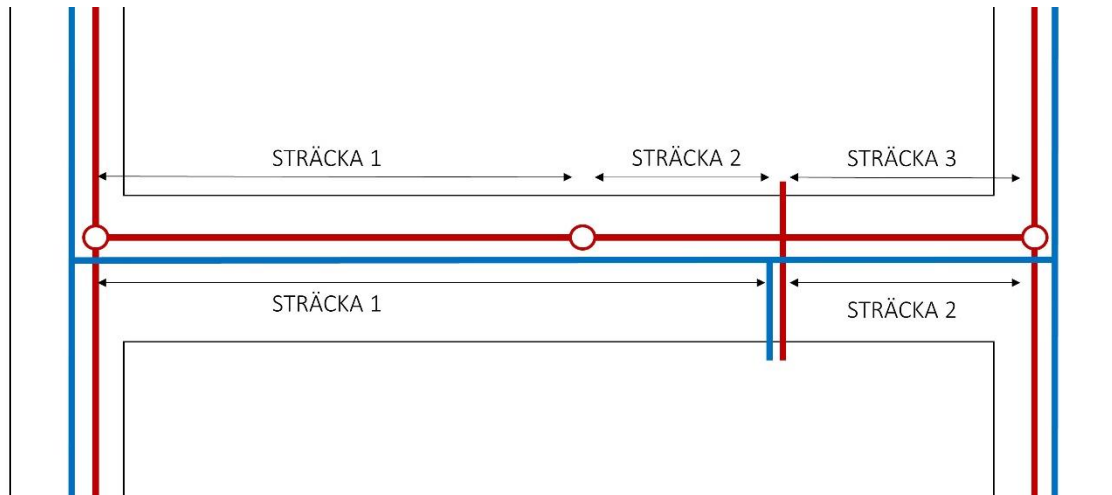
Den tidiga perioden (1) stämmer väl överens med utbyggnaden av Stockholms stad (Befolkningen i Stockholm 1252 – 2005, USK, Stockholm 2005), och även om befolkningen inte ökade i antal under andra perioden (2) 1950 till 1970 fortsatte bostadsbyggande i framförallt förorten under denna period. Den tredje perioden (3) beror på en större satsning för att bygga om ledningar som uppfyllt sin tekniska livslängd. Eftersom diagrammet visar befintliga ledningar så innebär detta att det har funnits andra ledningar som idag är utbytta p.g.a. skador eller som behövs byggas om i samband med exploateringar av olika slag.

4.2.2. Indelning av vattenledningsnätet

Vid införandet av digitala kartsystem i slutet av 1980-talet delades ledningsnäten upp i sträckor. En sträcka motsvaras ofta av ledningen mellan två brunnar för avloppsledningsnätet, alternativt kan en sträcka även vara ledningen mellan en brunn och en anslutande servis. För vattenledningsnätet gjordes samma indelning, ibland än mer förenklat, då typiskt sträckan mellan två ventiler. Vi fick

alltså sträckor som i vissa fall motsvarar en hel gata, och i vissa fall mellan anslutande serviser. I AI-beräkningen bestäms ett konditionsvärde per sträcka på vattenledningsnätet, det är alltså viktigt att känna till begreppet sträcka.

Vi har valt att arbeta med begreppet sträcka i AI-modellen. Detta innebär att sträckan har en förhöjd risk för läckage. I praktiken måste man alltså undersöka vidare vilken del av sträckan som har eventuella skador.



Figur 6. Varianter av sträckor.

4.2.3. Utvärdering av ett VA-ledningsnät


En analys av ett VA-ledningsnät kan göras med olika metoder. Det finns idag mer avancerade verktyg som Baseform och Prevoir som med olika metodik exempelvis beräknar behov av kommande underhåll, utveckling vad gäller läckage eller hur anläggningsvärdet förändras i framtiden. Det finns också enklare metoder som beskrivs i Svenskt Vattens förnyelseprojekt. I detta arbete ligger fokus på AI-modellens resultat som därefter jämförs med:

- Fakta om ledningsnätet.
- Fördelning av ett antal va-tekniska faktorer för ledningar med höga AI-riskvärden.
- Geografisk spridning av resultaten.

Vidare beskrivs och diskuteras även möjliga användningsområden för resultaten och potentiella effekter av dessa.

4.3. Resultat från AI-beräkningen

Nedan ser vi ett diagram som återigen visar de olika materialen i ledningsnätet (som ingår i AI-modellen). I detta diagram sker nu fördelningen med antalet ledningssträckor per byggår. Diagrammet följer det ovan vad gäller fördelning av de stora materielgrupperna och årtalen för utbyggnad.




Figur 7. Fördelning av antal sträckor per byggår och material.

I det fortsatta arbetet har indelningen med sträckor används, om inget annat anges.

4.3.1. Fördelning av konditionsvärdet


En översikt av vilka ledningar som har ett visst konditionsvärde visar att för de högre konditionsvärdena (över 0,5) så är gråjärn det dominerade materialet. Detta är inte helt oväntat då många undersökningar (Malm 2011) visar att gråjärn har en högre läckfrekvens än övriga material.



Figur 8. Konditionsvärde (0 till 1) för antal ledningar av olika material.

4.3.2. Konditionsvärde och material samt byggår


Är det alltid de äldre ledningarna som har en högre risk för skador och problem? I denna analys ser vi antal ledningar fördelat per byggår och konditionsvärde. Vi kan se att tidsperioden ca 1920 till ca 1965 är den grupp av ledningar som har flest sträckor med högst konditionsvärden. Det är också intressant att det finns ledningar byggda efter år 2000 som har ett konditionsvärde högre än 0,5.



Figur 9. Byggår och antal risksträckor (> 0,5) per material och byggår.

4.3.3. Extra högt konditionsvärde och material samt byggår

Nedan visas en bild med antal sträckor med förhöjd risk (konditionsvärde över 0,91) fördelat per år och material. Resultatet har viss likhet med diagrammet ovan, men det är intressant att det finns ledningar byggda efter år 2000 med förhöjda konditionsvärden. Vad gäller gruppen högrisksträckor i ledningar byggda de senaste 20 åren så är de byggda i materialen segjärn och PE (polyeten).




Figur

10. Byggår och antal högrisksträckor (> 0,91) per material och byggår.


4.3.4. Kumulativ distribution av konditionsvärden per material

För att få en ökad förståelse kring ledningsmaterialens enskilda konditionsnivåer kan dess kumulativa konditionsvärdesfördelning jämföras. På så vis kan man se vilket antal (eller procentuell andel) ledningsobjekt för respektive material som ligger över eller under ett visst konditionsvärde. I grafen nedan presenteras varje ledningsmaterials kumulativa fördelning av konditionsvärden, där gråjärn tydligt står ut med störst andel riskledningar (ca. 44 %, dvs nästan hälften av gråjärnsledningarna har konditionsvärden som överstiger 0,5).



Figur 11. Kumulativ konditionsvärdesdistribution fördelat per material

För en tydligare bild presenteras nedan riskledningsfördelning dels för alla inkluderade ledningar (och material) och dels för de tre ”huvudmaterialen” gråjärn, segjärn och pe.



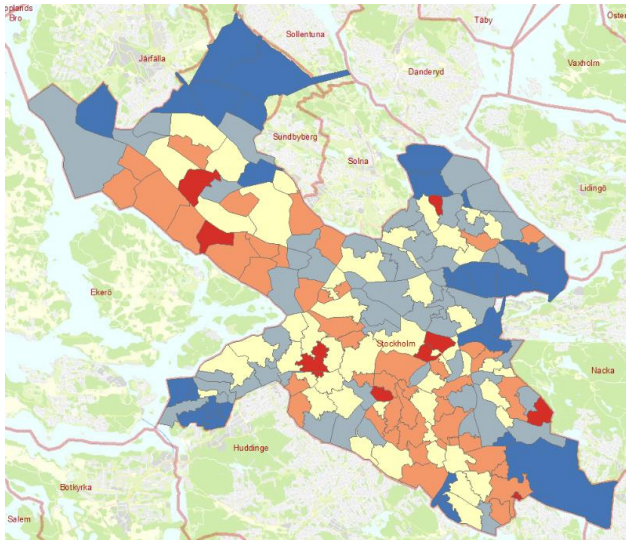
Figur 12. Fördelning av riskledningar för totalt ledningsnät (20,8 %), grå (43,6 %), seg (4,6 %) och pe (1,5 %)

4.3.5. Riskområden

Flertalet metoder kan tillämpas för identifiering av enskilda geografiska problemområden (områden med stort antal risk- och/eller högriskledningarna). Nedan redogörs för två metoder; båda med utgångspunkt i DUF-tekniken.

Metod 1

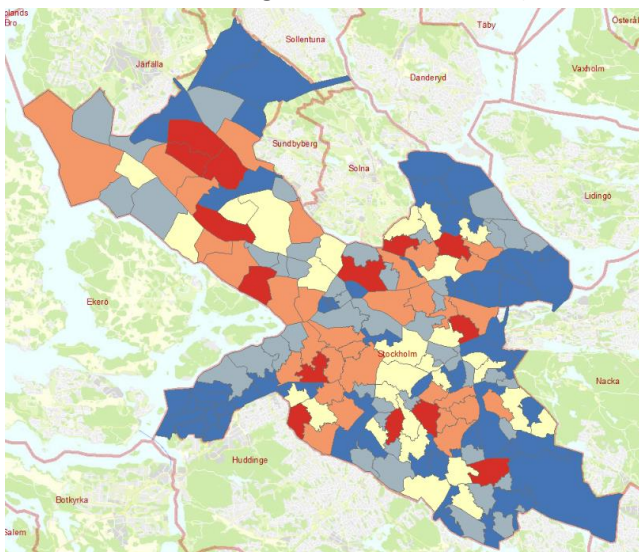
Aktuella DUF-områden klassificeras i en femgradig skala, beroende på hur stor andel riskledningar (antal riskledningar dividerat med totalt antal ledningar) som ligger i respektive område. Därefter färgsätts skalan i ArcMap (hög andel=rött område, låg andel=blått område) med följande resultat:



Figur 13. Andel riskledningar per DUF-område

Metod 2

Även här tillämpas en femgradig skala, men till skillnad från metod 1 är det *antal* riskledningar (och alltså inte *andel*) per DUF-område som tas i beaktande. Resultatet presenteras nedan (högt antal=rött område, lågt antal=blått område).




Figur 14. Antal riskledningar per DUF-område

4.3.6. Specifika ledningar med ett högre konditionsvärde

Eftersom ledningens beräknade (och faktiska) konditionsvärde deriveras av samspelet mellan alla de faktorer som influerar en lednings kondition, är det svårt att peka ut enskilda attribut med förhöjd påverkan. Med hjälp av statistisk visualisering kan dock vissa mönster urskiljas. Nedan presenteras analyser av hur riskledningars (konditionsvärde > 0,5) dimension, jordart och markanvändning/bebyggelse differerar mot genomsnittet.

Dimension


Ledningar med 100 respektive 150 mm dimension löper (relativt) högre risk för läckage.



Figur 15. Dimensionsfördelning (riskledningar & totalt)

Jordarter


Ledningar i morän respektive berg löper (relativt) högre risk för läckage.



Figur 16. Jordartsfördelning (riskledningar & totalt)

Markanvändning/Bebyggelse

Ledningar i anknäring till skogsområden löper (relativt) högre risk för läckage.




Figur 17. Markanvändningsfördelning (riskledningar & totalt)

Figur 18. Stadsdelar med hög andel risksträckor (t.v) och stadsdelar med högt medelläckage och stigande trend (t.h.).

4.3.7. Läckor 2018

I figuren nedan presenteras (av modellen beräknade) konditionsvärden för 155 läckor uppstådda under det gångna året (2018). En övervägande majoritet (96,13 %) av ledningssträckorna har alltså höga (> 0,5) konditionsvärden och de sträckor med låga värden har troligtvis inte läckt, utan felrapporterats (vilket inte är ett helt ovanligt fenomen i drifrapporteringsverktyget).



Figur 19. Beräknade konditionsvärden för läckande ledningar 2018.

5. Diskussion

5.1.1. Diskussion

Vid en jämförelse mellan resultatdatamängd och träningsdatamängd blir det uppenbart att en mängd ledningar som ursprungligen klassificerats med nollor troligen varit felklassificerade (eftersom antal riskledningsobjekt i resultatdatamängden överstiger antalet "läckledningar" i träningsdatamängden). Detta påvisar modellens stora potential att hitta mönster och värdera data som är felklassificerad, vilket gör den optimal för VA-ledningsnät (och speciellt vattennät) där det ofta är svårt att, på förhand, statusbedöma individuella ledningar.

Ovan nämnda felklassificering utgör även, tillsammans med "allmänt felaktig (och till viss del bristfällig) data", en huvudsaklig begränsning för modellen. Till följd av detta kommer vissa ledningsberäkningar "slå fel", men dessa har visat sig vara relativt få. Över tid kommer även denna begränsning bli allt mindre, i takt med att data fylls på och kvaliteten ökar.

Förslagsvis bör man fokusera åtgärdsplanering och läcksökning på de 7890 ledningsobjekt som beräknas vara "riskledningar". Ytterligare sortering kan här göras, då man även (likt ovan beskrivet) kan identifiera "högriskledningar" (1016 ledningsobjekt).

Inom åtgärdsplaneringen kan en naturlig följd av detta projekt vara att även inkludera konsekvens (av ledningsbrott) samt finansiella kostnader (för att få en övergripande bild av ledningars finansiella livslängd). Teoretiskt skulle liknande AI-modeller kunna beräkna enskilda ledningars framtida läcklagningskostnader, men brist på tillförlitlig data är här en stor utmaning. Även (objektiv) kvantifiering av konsekvens har sina svårigheter.

Överlag kan konstateras att artificiell intelligens (och ANN i synnerhet) har mycket goda förutsättningar att göra beräkningar på, och öka vår förståelse kring, våra VA-anläggningar. Potentialen för fortsatt användning inom andra delar av verksamheten tycks vara närmast oändlig och troligtvis kommer tekniken snabbt spridas inom branschen då den kan ge oss ökad möjlighet för intelligent, effektiv och objektiv beslutsfattning.

5.1.2. Fortsatt arbete

Under hösten har modellen presenterats vid olika konferenser och nätverksmöten. Resultatet har genererat stort intresse och många frågor samt diskussioner. För att ytterligare säkerställa AI-modellens funktion kommer VA-Syd, NSVA och Ängelholms kommun under våren 2019 att genomföra testkörningar och resultatet kommer att diskuteras och jämföras med SVOAs resultat.

Som nämnts ovan bör resultatet också kunna användas för att göra bedömningar av omfattningen av det övergripande underhållsbehovet (leta läckor / laga läckor) samt när ledningar uppnått sin tekniska livslängd (förnyelse). Detta såväl i teknisk som ekonomiskt perspektiv.

6. Slutsatser och rekommendationer

Med AI-tekniken kan SVOA göra bättre antaganden om vilka problemområden och ledningar som har en större risk för att drabbas av läckor. Användningsområdet är framförallt inom förebyggande underhåll (FU) där aktiv läcksökning kan styras mot områden med höga risktal. Resultaten hittills är mycket trovärdiga och ytterligare verifiering skall ske av fler va-organisationer. Tekniken bör även kunna tillämpas inom fler områden, exempelvis prediktion av risker inom avloppsledningsnätet baserat på resultat från TV-inspektioner eller förutsägelse av produktionsbehov av dricksvatten.

Författaren rekommenderar att SVOA implementerar AI-funktionalitet för riskberäkningar inom vattenledningsnätet i sin dagliga verksamhet, och att sonderingar görs kring möjligheter att utveckla ett professionellt verktyg.

7. Referenser

Malm, Annika, (2011) *Rörmaterial i svenska VA-ledningar – egenskaper och livslängd*, Stockholm: Svenskt Vatten Utveckling

Maltarollo et al, (2013) *Applications of Artificial Neural Networks in Chemical Problems*, IntechOpen

USK, (2005) *Befolkningen i Stockholm 1252 - 2005*, Stockholm: USK

Stockholm Vatten och Avfall är en samhällsbyggare i framkant som driver och utvecklar vatten- och avfallstjänster med miljöfokus. Varje dag, året runt förser vi 1,4 miljoner stockholmare med rent och gott kranvatten, renar avloppsvatten och ser till att avfallet tas om hand. Tillsammans med invånare, företag och andra intressenter arbetar vi för att Stockholm ska bli världens mest hållbara stad.



Stockholm Vatten och Avfall

Tel 08-522 120 00

svoa@svoa.se

www.svoa.se

En del av Stockholms stad