

GÅR DET ATT UPPTÄCKA PUMPFEL MED MASKININLÄRNING BASERAT PÅ LJUD?

Arbetet visar att man med hjälp av maskininlärning kan analysera ljud för att upptäcka slitage och fel i pumpar med hög noggrannhet. Flera metoder testades med något varierande resultat, samtidigt som utmaningar i verkliga miljöer identifierades.

En pump som går sönder kan få konsekvenser som är allt ifrån ett mindre besvär till en katastrof. Pumpar finns på otaliga platser, varav flera är avskides eller svåråtkomliga. Därför hade det varit fördelaktigt att kunna montera en sensor som övervakar pumpen och kan identifiera när den börjar bli sliten eller drabbats av andra fel. Arbetets mål var därför att upptäcka fel i pumpar genom att analysera ljud med hjälp av maskininlärning. Att använda ljud är fördelaktigt då det i teorin inte skulle kräva några ingrepp eller någon integration med pumpen.

För att uppnå detta testades tre olika maskininlärningsmetoder, CNN (Convolutional Neural Network), MLP (Multilayer Perceptron) och SVM (Support Vector Machine), och två olika metoder för att extrahera användbar information från ljud, som kan behandlas av en maskininlärningsmodell: log-mel spektrogram och MFCC. Dessa metoder visualiserar frekvensinnehållet över tid som en bildrepresentation. Detta gav upphov till sex olika kombinationer av metoder som testades på två olika dataset.

Det första är ett dataset förkortat MIMII som innehåller fyra olika ljudkällor, bland annat ljudinspelningar från fyra olika pumpmodeller. Det andra datasetet spelade vi in själva där fel skapades artificiellt genom att vi på olika sätt saboterade en pump och två positioner för mikrofonen användes. På dessa dataset utfördes sedan totalt fem olika experiment med samtliga kombinationer av metoder:

- Träning, validering och testning med ljudklipp från samtliga pumpar i MIMII datasetet.
- Träning och validering på tre av pumparna i MIMII datasetet och sedan testning på den fjärde pumpen.
- Modellerna tränade på MIMII datasetet från det första experimentet testades på vårt eget dataset.
- Träning, validering och testning på en kombination av MIMII datasetet och vårt eget dataset.
- Träning och validering på en mikrofonposition från vårt eget dataset och testning på den andra mikrofonpositioneringen.

Experimenten visade på att samtliga kombinationer av metoder kunde klassificera ljud i någon utsträckning. I och med att ljudklippen i vårt eget dataset är väldigt lika då de härstammar från samma källa var det möjligt att nå 100% eller nära 100% noggrannhet på vårt eget dataset med samtliga kombinationer när modellerna tränades på båda dataseten. När modellerna tränades på MIMII datasetet varierade resultaten något mer och det var tydligt att log-mel spektrogram gav bättre resultat jämfört med MFCC. Av metoderna för maskininlärning var det väldigt jämnt mellan CNN och MLP, där MLP presterade något bättre när log-mel spektrogram användes medan CNN gav bättre resultat när MFCC användes. Alltså presterade kombinationen av MLP och log-mel spektrogram bäst överlag på MIMII datasetet med 98.07% noggrannhet.

De övriga experimenten visade däremot att det är svårt att generalisera och samtliga kombinationer misslyckades när de ställdes inför en pumpmodell eller en mikrofonposition de inte hade tränats på. Detta ledde oss till slutsatsen att klassificering av ljud med hjälp av maskininlärning har stor potential men att det finns utmaningar som man antingen måste lösa eller anpassa sig till.