

**Modellering av hybridanläggning samt utveckling av
övervakningssystem för Västhamnsverket baserat på
Artificiella Neurala Nätverk**

©Svenskt Gastekniskt Center – December 2006

Mohsen Assadi & Magnus Fast
INSTITUTIONEN FÖR ENERGIVETENSKAPER
LUNDS TEKNISKA HÖGSKOLA

SGC:s FÖRORD

FUD-projekt inom Svenskt Gastekniskt Center AB avrapporteras normalt i rapporter som är fritt tillgängliga för envar intresserad.

SGC svarar för utgivningen av rapporterna medan uppdragstagarna för respektive projekt eller rapportförfattarna svarar för rapporternas innehåll. Den som utnyttjar eventuella beskrivningar, resultat eller i rapporterna gör detta helt på eget ansvar. Delar av rapport får återges med angivande av källan.

En förteckning över hittills utgivna SGC-rapporter finns på SGC's hemsida www.sgc.se.

Svenskt Gastekniskt Center AB (SGC) är ett samarbetsorgan för företag verksamma inom energigasområdet. Dess främsta uppgift är att samordna och effektivisera intressenternas insatser inom områdena forskning, utveckling och demonstration (FUD). SGC har följande delägare: Svenska Gasföreningen, E.ON Gas Sverige AB, E.ON Sverige AB, Lunds Energi AB, Göteborgs Energi AB, och Öresundskraft AB.

Följande parter har gjort det möjligt att genomföra detta utvecklingsprojekt:

Statens Energimyndighet
Värmeforsk AB
Siemens Industrial Turbomachinery AB
Öresundskraft Produktion AB

SVENSKT GASTEKNISKT CENTER AB



Jörgen Held

Abstract

Simulering och övervakning av termiska kraftverk för ökad tillgänglighet och effektivare underhåll underlättas betydligt med artificiella neurala nätverk. Det är även möjligt att skapa ett tillhörande användarvänligt gränssnitt i t.ex. Excel miljö. Gällande gasturbinen är det visat att det finns stora möjligheter att i framtiden skapa ANN modeller baserade på simuleringsdata. Detta i sin tur möjliggör leverans av ANN tillsammans med nya gasturbiner.

Sammanfattning

Projektet avser modellering av hybridanläggningen vid Västhamnsverket i Helsingborg med hjälp av artificiella neurala nätverk (ANN). Med hybridanläggning menas den biobränsleeldade ångcykeln som kombinerats med en modern gasturbin och tillhörande avgaspanna. Projektet är en uppföljning av tidigare projekt. Vid tidigare projekt har i stor utsträckning simuleringsdata använts för ANN modellering medan ANN modellering i det nuvarande projektet är baserad på driftdata från anläggningen. Gastrubinen representerar det delsystem av anläggningen som haft störst fokus i tidigare projekt. Så är fortfarande fallet men även avgaspanna, ångpanna och ångturbin modelleras eftersom övervakning av hela anläggningen är av intresse. De färdiga modellerna kopplas samman i ett nätverk som kan användas dels för offline simulering men även för tillståndsovervakning i realtid. En produkt, innefattande alla delsystem, skapas i form av ett användarvänligt gränssnitt i Excel miljö vilken kan användas t.ex. för kontinuerlig övervakning, träning av ny driftpersonal och planeringsstöd för driften.

Målgruppen för projektet är kraftverksägarna samt gasturbintillverkarna. Kraftverksägarnas intresse ligger i att erhålla en produkt som kan användas för exempelvis planering av driften samt stöd till beslut om underhåll på grund av degradering. Gasturbintillverkarnas huvudintresse ligger i att undersöka möjligheten att kunna leverera ANN modeller, tränade med syntetisk data, tillsammans med nya gasturbiner.

Projektet har genomförts på LTH med stöd av Västhamnsverket och Siemens. Västhamnsverket har tillhandahållit driftdata från anläggningen samt stöd till analys av delsystemens funktion. Siemens har bidragit med expertkunnande om gasturbinen, SGT800. Datan som mottagits har undersökts och filtrerats vart på den använts för träning av ANN modeller. Modellerna har sedan validerats med oberoende data.

Resultaten är mycket lovande då ANN modellerna visat hög noggrannhet i sina prediktioner. Alla delsystem har visat sig modellerbara och det finns även stora möjligheter till vidareutveckling av modellerna. Resultaten har visat att det finns möjligheter att träna gasturbin modeller med syntetisk data. För att kunna dra några djupare slutsatser om detta måste dock fortsatt forskning utföras. En slutsats om projektet i sin helhet är att ANN visar sin mångsidighet samt har stor potential att användas inom området termiska kraftverk.

Målen med projektet anses av författarna i stort vara uppfyllda.

Sökord: ANN modellering, termiska kraftverk, degradering, övervakning, gasturbin

Summary

The project aim is to model the hybrid plant at Västhamnsverket in Helsingborg using artificial neural networks (ANN). The definition of a hybrid plant is that it uses more than one fuel, in this case a natural gas fuelled gas turbine with heat recovery steam generator (HRSG) and a biomass fuelled steam boiler with steam turbine. The models in the present project are based on operational data from the plant in contrary to previous projects where synthetic (simulated) data has been used in a large extent. The gas turbine represents the subsystem that has received most attention in previous projects, which will also be the case for the present project although models of the HRSG, steam boiler and steam turbine are created since the whole plant is of interest. The completed ANN sub modules are connected in a network, which can be used for e.g. offline simulation and real-time condition monitoring of the plant. A product, including all sub modules, is created in shape of a user-friendly interface in an MS Excel environment. This user interface can be used for continuous monitoring, training personnel and in planning of the operation.

The target group is the plant owners and the original equipment manufacturers (OEM). The plant owners interest lies in receiving a product that can assist them when operating the plant, for instance supply them with information about the grade of degradation. The OEMs main interest lies in investigating the possibilities of delivering ANNs, based on synthetic data, along with their new gas turbines.

The project has been carried out at Lunds University, Department of Energy Sciences, with support from Västhamnsverket and Siemens. Västhamnsverket have contributed with operational data from the plant as well as support in plant related questions. Siemens have contributed with expert knowledge about their gas turbine, the SGT800. The received data has been examined and filtered before used for training ANN models. The models have been evaluated with independent data.

The results are very promising with ANN models showing high prediction accuracy. All subsystems can be modeled with ANN and there are also possibilities of further development. The results have shown that there is potential in developing gas turbine models based on synthetic data but in order to draw any conclusions in this matter further research has to be carried out. A conclusion about the project as a whole is that ANN shows great versatility along with potential to be used within the field of thermal power plants.

The project goals are considered to be fulfilled by the authors.

keywords: ANN modeling, thermal power plant, degradation, monitoring, gas turbine

Innehållsförteckning

1	INLEDNING	1
1.1	BAKGRUND	1
1.2	BESKRIVNING AV FORSKNINGSSOMRÅDET	1
1.3	FORSKNINGSUPPGIFTEN OCH DESS ROLL INOM FORSKNINGSSOMRÅDET	1
1.4	MÅL OCH MÅLGRUPP	2
2	VÄSTHAMNSVERKET, HYBRIDANLÄGGNING	3
2.1	GASTURBINEN, SGT800	3
2.2	ÅNGTURBINEN, ATM	4
2.3	AVGASANNAN	5
2.4	ÅNGPANNAN	6
3	KORT OM ANN	7
3.1	ANN KONFIGURATION ANVÄND I DETTA PROJEKT	9
4	MODELLERING AV GASTURBINEN.....	10
4.1	DRIFTDATA OCH DATAFILTRERING/BEHANDLING	10
4.2	JÄMFÖRELSE MELLAN TIDIGARE ANN MODELL OCH NY	11
4.3	DEN NYA ANN MODELLEN FÖR SGT800.....	17
4.4	ANVÄNDARGRÄNSSNITT FÖR GASTURBINMODELLEN.....	20
4.5	FRAMTIDA ARBETE.....	21
5	MODELLERING AV AVGASANNAN	22
5.1	DRIFTDATA OCH DATAFILTRERING/BEHANDLING	22
5.2	ANN MODEL FÖR AVGASANNAN	22
5.3	ANVÄNDARGRÄNSSNITT FÖR AVGASANNAMODELLEN.....	26
5.4	FRAMTIDA ARBETE.....	26
6	MODELLERING AV ÅNGPANNAN	27
6.1	DRIFTDATA OCH DATAFILTRERING/BEHANDLING	27
6.2	ANN MODELL FÖR ÅNGPANNAN	27
6.3	ANVÄNDARGRÄNSSNITT FÖR ÅNGPANNAMODELLEN	30
6.4	FRAMTIDA ARBETE.....	30
7	MODELLERING AV ÅNGTURBINEN	31
7.1	DRIFTDATA OCH DATAFILTRERING/BEHANDLING	31
7.2	JÄMFÖRELSE MELLAN TIDIGARE ANN MODELLER OCH NY	31
7.3	DEN NYA ANN MODELLEN FÖR ÅNGTURBINEN.....	32
7.4	ANVÄNDARGRÄNSSNITT FÖR ÅNGTURBINMODELL	33
7.5	FRAMTIDA ARBETE.....	34
8	KOPPLING/SAMVERKAN MELLAN ANN MODELLER	35
8.1	ANVÄNDARGRÄNSSNITT FÖR HELA HYBRIDANLÄGGNINGEN	36
9	RESULTATREDOVISNING	38
9.1	ERFARENHETER FRÅN MODELLERINGSARBETET.....	39
10	RESULTATANALYS	40
11	SLUTSATSER.....	42
12	DISKUSSION.....	43

13	FÖRSLAG TILL FORTSATT FORSKNINGSARBETE.....	44
14	LITTERATURREFERENSER	45

1 Inledning

1.1 Bakgrund

Projektet, som är samfinansierat av Värmeforsk och Svenskt Gastekniskt Center (SGC), avser modellering av hybrid anläggningen vid Västhamnsverket i Helsingborg med hjälp av artificiella neurala nätverk (ANN) där övervakning av anläggningsdegraderingen står i fokus.

Kraftvärmeverket består av en modern gasturbin från Siemens, SGT800, med tillhörande avgaspanna samt en biobränsleeldad ångpanna med tillhörande ångcykel. Ånga från ångpannan och avgaspannan expanderar i en gemensam, ombyggd mottrycksturbin.

För att realisera konditionsbaserat underhåll krävs kontinuerlig övervakning av delsystemen i kraftverket. Mätdata som genereras under drift skall ligga till grund för utveckling av ANN modellerna som sedan används för anläggnings övervakning. Avvikelser från förväntat datamönster indikerar komponentfel som operatören uppmärksammas att åtgärda. Snabb detektering av fel leder därmed till reducerade underhållskostnader.

1.2 Beskrivning av forskningsområdet

ANN modellering av kraftverkssystem är relativt nytt område även om ANN verktyget har använts inom andra discipliner rätt så länge. Forskarstudier som bedrivits på avdelningen för kraftverksteknik på LTH under senare år har utgjort de första försöken till att använda ANN för kraftverksmodellering och övervakning. Nuvarande projekt är en fortsättning på dessa arbeten. [1][2][4] [8][9]

1.3 Forskningsuppgiften och dess roll inom forskningsområdet

Projektet är fortsättning på tidigare studier om Västhamnsverket där främst ”syntetisk data”, genererade med olika värmebalansprogram, användes för modellering, övervakning och feldiagnostik. Den här aktuella studien avser upprepning av tidigare arbete dock med hjälp av verklig driftdata från anläggning. Ett av huvudmålen för projektet är att jämföra resultat från modellering med syntetiskt data med resultat baserade på verklig driftdata för att kartlägga/evaluera användbarheten av värmebalansprogram som hjälpmedel för datagenerering och träning av ANN modeller för termiska kraftverksanläggningar.

Ökad tillgänglighet och billigare samt effektivare underhåll för bränslebaserade kraftverk är huvudintresset för denna forskning. Genom att koppla mätdata, genererade under drift, till analys av anläggningens kondition och prestanda kan så väl underhåll som prestanda för anläggningen optimeras.


1.4 Mål och målgrupp

Målet med projektet är dels att skapa en färdig produkt i form av ett användargränssnitt som senare ska utvärderas på Västhamnsverket. Användargränssnittet ska innehålla separata modeller av gasturbin, avgaspanna, ångpanna, samt ångturbin som kopplas samman i ett nätverk. Vidare ska projektet belysa möjligheter med att skapa modeller för simulering och tillståndsovervakning av termiska kraftverk och dess delsystem.

Målgruppen består av kraftverksägare och gasturbintillverkare. Kraftverksägarens intresse ligger i att kunna övervaka sin anläggning på ett effektivt och enkelt sätt och med hjälp av framtagna modeller kunna få stöd i underhållsrelaterade frågor. Gasturbintillverkarnas intresse ligger i att kunna leverera ett ANN tillsammans med nya gasturbiner.

2 Västhamnsverket, hybridanläggning

Västhamnsverket i Helsingborg är ett ångkraftverk, uppfört 1982, för el- och värmeproduktion med en fastbränslepanna för kol, träpellets och olja samt en ångturbin med värmeavtappning. Verket hade före tillbyggnaden en kapacitet av 64 MWe och 132 MW_v, vilket gav ett alfavärde på 0.48. Vidare finns här en eldriven varmepump med 29 MW värmeeffekt och en hetvattenackumulator med en kapacitet på 1500 MWh. Tillbyggnad av en gasturbinanläggning med avgaspanna har ökat kraftvärmeverkets kapacitet för el- och värmeproduktion. Ångan från avgaspannan leds till befintlig, uppgraderad turbin, som dessutom förses med ånga från befintlig fastbränslepanna. Västhamnsverket tillhör kategorin hybridanläggningar eftersom ångan i anläggningen genereras m.h.a. olika bränslen. Totaleffekten för hybridanläggningen är 126,7 MWe och 186 MW_v och systemlösningen är unik. Till exempel har alfavärdet höjts till 0.68, vilket innebär en väsentlig effektivisering och ett bättre utnyttjande av fjärrvärmenätet för elproduktion. Utöver Västhamnsverket försörjs fjärrvärmenätet i Helsingborg av spillvärme från en kemisk industri (Kemira), som i genomsnitt levererar 27-30 MW_v, samt från hetvattencentralen ”Israel”, som har en kapacitet på nästan 400 MW_v. Pannorna här kan huvudsakligen eldas med olja, men naturgas kan användas i två pannor på totalt 60 MW_v. [3]



Figur 1. Förenklat kopplingsschema av hybridanläggningen [6]

2.1 Gasturbinen, SGT800

Maskinen är utlagd för 43 MW och en termisk verkningsgrad på 37 %. Gasturbinen har även mycket låga emissionsnivåer (<15 ppm NO_x på gasbränsle).




Figur 2. Siemens SGT800 gasturbin [3]

Maskinen är enaxlig och driver generatoren med den "kalla" sidan (detta innebär t.ex. att man kan ha en effektiv lång konisk diffusor efter turbinen, se figuren ovan). Kompressorn består av 15 steg och tryckförhållandet är ca 20, med ett flöde på ca 130 kg/s. I brännkammaren tillförs bränsleeffekt på ca 120 MW och temperaturen efter brännkammaren är ca 1200°C. Gasen expanderar sedan genom turbinens 3 steg där man erhåller ca 100 MW turbinarbete (motsvarar ett arbete på ca 550 hk per roterande skovel). Eftersom maskinen är optimerad för kombicykel är avgastemperaturen relativt hög. Då inga idag kända belastade skovelmateriel tål mer än ca 950°C, är turbinens 2 första steg luftkylda. [3]

Den första SGT800 (produktionsprototypen) levererades till Helsingborg under 1999 och togs i drift för de första verifieringsproven senhösten 1999. För närvarande, september 2006, är 43 stycken SGT800 sålda varav 19 stycken i kommersiell drift. Två av dessa har 40 000 EOH samt 7 maskiner har över 20 000 EOH, den totala drifttiden är 373 000 EOH.

2.2 Ångturbinen, ATM


Ångturbinen som används i botten-cykeln är den ursprungliga axialturbinen, från uppförandet av Västhamnsverket. I och med att verket byggdes om för kombidrift, modifierades ångturbinen för att kunna släppa igenom bidraget från kombipannan, med bibehållna admissionsdata. ATM-maskinen är en oväxlad fullvarvsmaskin med låg reaktionsgrad, som utvecklades i Finspång, av dåvarande STAL-LAVAL (numera Siemens Industrial Turbomachinery AB) under slutet av 1970-talet. Ångturbinen har i detta utförande partialpådrag, med symmetriska pådragsbågar (1+1, 1, 1) och ett Curtis-steg. Maskinen är försedd med tre avtappningar till högtrycksförvärmaren, matarvattentanken och lågtrycksförvärmaren. Vidare används två värmekondensorer i traditionell två-stegs koppling och flödena separeras med Baumannsteg (2 + 3). Totala antalet steg är 25. Denna turbintyp har ett välförtjänt rennomé som robust och mycket driftsäker, med litet underhållsbehov. [3]



Figur 3. ATM maskin i kondensutförande [3]

Ångturbinen anpassades för det ökade ångflödet, innan gasturbinen togs i drift, genom att öka bågarean i reglersteget samt ny beskovling i resterande turbinen exklusive Baumann-stegen. Denna modifiering innebär bland annat att relationen mellan stegtryck och flöde genom ett visst steg inte är samma efter ombyggnaden. På grund av detta kommer endast mätdata efter ombyggnaden att användas i projektet. [3]


2.3 Avgaspannan



Figur 4. Schematisk bild över avgaspannan tagen från kontrollpanel

De heta rökgaserna från gasturbinen värmeväxlas i en ekonomiser, förångare samt två överhettare för att producera ånga till ångturbinen. Avgaspannan som är av entryckstyp levererar vid fullast ca 15 kg överhettad ånga per sekund vid 105 bar och 520°C. Utöver detta finns även en fjärrvärme ekonomiser med ett ungefärligt effektuttag på 20 MW.

2.4 Ångpannan



Figur 5. Schematisk bild över pannan tagen från kontrollpanel

Pannan, som numera eldas med 100% biobränsle, består i stora drag av en ekonomiser, ångdom, förångare samt ett antal överhettare. Atmosfärluften förvärms i en luftförvärmare av system Ljungström. Konvertering till biobränsle har krävt ombyggnader av både bränslekvarnar och rökgasfläkt för att hantera de större flödena av så väl bränsle som rökgas. Värmeeffekten i pannan är ca 250 MWth och den levererar ca 80 kg över hettad ånga per sekund vid 110 bar och 540°C. Bränsleinmatningen sker tangentiellt i tre olika nivåer i pannan.

3 Kort om ANN

Tillskillnad från traditionella matematiska modeller, som programmeras, så lär sig ANN samband mellan indata och utdata. Detta görs i en process som kallas träning, där data presenteras för ANN i en iterativ process. Det naturliga kravet blir då att data (både in- och utdata) måste finnas tillgängligt. ANN hittar samband (så länge där finns ett samband) mellan indata och utdata oavsett om dom är enkla, oerhört komplicerade eller t.o.m. okända. För att exemplifiera det hela så används nedanstående ekvation för att generera lite in- och utdata till Tabell 1. [1][7]


$$y = \frac{x^2}{3}$$

Tabell 1. In- och utdata genererade av ekvation

x (indata)	y (utdata)
3	3
6	12
9	27
12	48
15	75
18	108
21	147


Låt oss säga att ekvationen, som representerar sambandet mellan in- och utdata, är okänd men tabellen med data finns tillgänglig. I ett sådant scenario kan ANN tränas med datan för att hitta sambandet mellan x och y. Efter träningen så låses nätverket och när ny indata presenteras så genereras motsvarande utdata. Säg x = 10 används, då skulle ANN svara med y = 33.3 (eller åtminstone väldigt nära, beroende på framgången vid träningen). Denna förmåga, att leverera utdata från tidigare osedd indata, kallas generalisation. Man kan jämföra processen med en kurvanpassning.

Nu är ANN inte begränsad till att bara ha en in- och utparameter utan lämpar sig väl för icke linjära multidimensionella system, d.v.s. flera in- och utdata med icke linjära samband enligt Figur 6. [1]



Figur 6. Icke linjärt, multidimensionellt system [1]

För att få en inblick i hur själva ANN är uppbyggt så visas i Figur 7 en artificiell neuron tillsammans med de vanligaste överföringsfunktionerna.




Figur 7. Schematisk representation av en artificiell neuron samt vanliga överföringsfunktioner [1]

Det som händer i en neuron är att indata (i denna figur y_a samt y_b) multipliceras med sina respektive vikter (w_{ka} och w_{kb}) för att sedan summeras till en s.k. effektiv indata (s_k) vart på denna passerar genom en överföringsfunktion (i bilden syns 4 exempel för funktioner, men i verkligheten väljs endast en beroende på problemets beskaffenheter). Det som kommer ut ur överföringsfunktionen är själva utdatan, y_k . Ettan som syns ovanför indata är en s.k. bias som representerar en offset och även den multipliceras med sin egen vikt, w_{k0} . [1]

När träningen initieras så tilldelas vikterna randomiserade värden vart på de första indata presenteras för modellen. Självklart kommer den utdata som genereras inte matcha den verkliga utdatan. Felet som uppstår, mellan predikterad utdata och verklig utdata används för att uppdatera vikterna (w_{ka} , w_{kb} samt w_{k0}). Vikterna justeras utifrån respektive indatas inflytande på utdata. Denna process motsvarar en epoch (iteration) och för varje genomförd epoch så kommer felet mellan predikterad och verklig utdata att minska. [1][7]


Eftersom varje neuron bara har en utdata så bygger man upp nätverk av neuroner lagervis (därför neurala nätverk), vanligtvis bestående av ett indata, ett dolt och ett utdata lager enligt Figur 8. För att anpassa nätverket för bästa prestanda så kan antalet neuroner i det dolda lagret varieras.



Figur 8. Artificiellt neuralt nätverk med ett indata, ett dolt och ett utdata lager [3]

Den totala datamängden delas upp i tre delar innan träning, en del för just träning, en för validering och en för test. Tränings delen används för att generera felen (som beskrivs ovan) medan validerings delen används för att testa nätverkets prestanda under träning för att undvika överträning. Den sista delen, test delen, används för att kontrollera nätverket med oberoende data efter det är färdigtränat (jämför $x = 10$ i exemplet det tidigare exemplet). [1]

Innan datan används för träning så måste den normaliseras för att undvika att en signal som är större än de andra blir dominant, efter träningen denormaliseras datan igen. [1]



Figur 9. Förbehandling och efterbehandling av data [1]

3.1 ANN konfiguration använd i detta projekt

Vid modellering av termiska kraftverk har det visat sig, genom mångårig erfarenhet inom institutionen, att användande av en ANN struktur med ett indata lager, ett dolt lager samt ett utdata lager är att föredra. Det har även visats att ett dolt lager räcker för att uppskatta vilken kontinuerlig funktion som helst [1]. Vad gäller överföringsfunktioner så har tangens hyperbolicus använts då den har icke linjära egenskaper som är önskvärda vid modellering av anläggningar med icke linjärt beteende. Data har, utifrån erfarenhet, normaliserats i intervallet -0.8 till 0.8 vilket bl.a. medför att det resulterande nätverket kommer att ha viss förmåga till extrapolation [5]. Bakom varje ANN modell ligger en variation av antalet neuroner i det dolda lagret. Dessa variationer utförs i regel i intervallet 5 till 20 vart på det bäst konvergerande nätverket sparas. Att ange exakt vilken konfiguration som sparats för respektive modell anses inte vara av någon större vikt eftersom det kan variera från träning till träning (statistiska modeller).


4 Modellering av gasturbinen

Tanken med att modellera gasturbinen med ANN är att få fram ett verktyg som kan användas för övervakning och tillståndsbestämning. Med tillståndsbestämning menas exempelvis spårning av prestandadegradering. För att detta ska fungera så är det av stor vikt att data som används för modellering och senare jämförelse är insamlade under en period då gasturbinen är frisk och presterar som förväntat (eleffekt, verkningsgrad, etc.). Denna uppsättning av data som utgör referensfallet kallas också för baseline. Baseline för SGT800 i Helsingborg fastställdes till 28/1 2006 då kompressortvätt samt inspektion av skovlar utfördes. Data som används för träning av GT modeller är därmed insamlad efter detta datum och anses vara ”frisk” data.

De modeller som tagits fram inom tidigare projekt har baserats på syntetisk data (simulerad data). Bland annat har en modell för feldiagnostik tagits fram [2]. Denna modell är tränad för att identifiera de 10 vanligaste felen hos gasturbinen. Vidare har ett ANN för modellering av gasturbinen och simulering av turbinprestanda tagits fram. Som indata har last, atmosfärstemperatur samt relativ fuktighet använts. Som utdata har eleffekt, verkningsgrad, heat rate (d.v.s. inversen till verkningsgraden), bränsleflöde samt rökgastemperatur använts. Syntetisk data för ANN-modellering genererades med designverktygen för denna turbin i samarbete med Siemens i Finspång.

4.1 Driftdata och datafiltrering/behandling

Driftdata för SGT800 levererades till LTH i form av Excel filer innehållande ca 70 driftparametrar sparade som 5 minuters medelvärden och insamlade under perioden februari till april. Data insamlad under februari har använts för modellering eftersom gasturbinen kördes kontinuerligt under denna period. Vissa av dessa driftparametrar, bl.a. kompressor tryck- och temperatur, finns illustrerade i Figur 10.



Figur 10. Gasturbinen GTX100 med de viktigaste driftinstrumenten markerade [3]

Den utvalda datamängden har undersökts och filtrerats för att undvika att felaktig data används för träning av modellen. Detta görs på två sätt, dels undersöks datan innan träning för att avlägsna uppenbart oriktig data (oriktig data kan t.ex. vara då en sensor misslyckas att leverera ett värde). Det andra sättet att hitta felaktig data är att, efter alla

uppenbara fel borttagits, träna ett preliminärt ANN för att sedan validera detta. Uppkommer det då perioder, t.ex. vissa tidsintervall, där felen är utmärkande stora så kan man oftast i efterhand reda ut varför och även ta bort denna data. Efter detta är gjort så tränas ett nytt ANN utan dessa perioder och förhoppningsvis förbättras prestanda för modellen. Vidare måste även transienter tas bort, t.ex. då lasten ändras eller då anti icing går i drift eller tas ur drift. Eftersom datan består av 5 minuters medelvärden så kan inga transienter modelleras då detta kräver mycket finare upplöst data, t.ex. sekundvärden eller liknande. Alltså, endast de perioder där gasturbinen befinner sig i stationär drift ska finnas med i den slutliga datamängden. Efter all filtrering återstod 7239 rader data i ett Excel blad (modelleringsdata) där 60 % användes för träning, 15 % för validering under träning och 25 % för test efter träning.

4.1.1 Klassificering av data i diskreta grupper

I fallet VHV körs gasturbinen vid två specifika lastlägen, närmare bestämt fullast eller begränsad till 30 MW. Dessa kan separeras med hjälp av en parameter som antar värdet ett eller noll beroende på rådande läge. Att urskilja dessa driftslägen görs enklast genom att studera den producerade eleffekten, fullast innebär dryga 40 MWe.

Anti icing fungerar på samma sätt, d.v.s. antingen är den på eller av, och även dessa lägen åtskils med en parameter som antar värdet ett eller noll. För att ta reda på om anti icing är igång så har bl.a. en parameter kallad anti icing flöde studerats. Anti icing flöde anger hur mycket fjärrvärme som används för att värma inloppsluften till gasturbinen. Anti icing aktivitet finns även att tillgå genom en egen signal men denna var tyvärr ej tillgänglig vid modelleringstillfället. För att ANN ska kunna följa dessa förändringar har Excel dokumentet med data utökats med två kolumner, en för varje "tillstånds" parameter. Dessa kolumner består som sagt av ettor och nollor som anger rådande tillstånd.

4.2 Jämförelse mellan tidigare ANN modell och ny

Den nya ANN modellen som är framtagen med driftdata skiljer sig ganska markant från den ursprungliga modellen, som var baserad på syntetisk data (simulerad data) m.a.p. använda in- och utdata. Ett exempel på sådana skillnader är att lasten (procent av maxeffekt) inte finns uppmätt/registrerad och kan därför inte ingå som indata till den nya modellen. Som tur är körs gasturbinen oftast för två diskreta lastfall, nämligen fullast respektive begränsad till 30 MW. Detta möjliggör införande av en, till lasten motsvarande, indata i form av en etta eller nolla (beroende på rådande lastfall) som särskiljer lastfallen åt och gör det möjligt för ANN att modellera båda fallen. Övriga driftsfall är underrepresenterade bland insamlad data och är därför inte användbara för modelleringsarbete. Detta innebär en klar begränsning för modellen men då lasten inte är tillgänglig anses det vara den bästa utvägen. Gasturbinen körs dock uppskattningsvis 99 % av tiden på antingen fullast eller begränsad till 30 MW. Anledningen till att gasturbinen körs på just 30 MW är att det anses vara den lägsta effekt som inte ger allt för dåliga miljödata samtidigt som man inte vill stänga gasturbinen helt då värmen fortfarande är begärlig.

Vidare så har atmosfärstrycket inkluderats och relativ fuktighet tagits bort som indata i den aktuella ANN modellen. Detta görs med stöd av erfarenhet från modellering av andra gasturbiner där det visat sig att den relativa fuktigheten inte har någon inverkan på prestanda vilket atmosfärstrycket däremot har. Den relativa fuktigheten är dock viktig för anti icing systemet som beskrivs här näst. [5]


Ytterligare ett tillägg i den nya modellen är en indata som anger om anti icing är i drift eller ej. Den här parametern kan ses som en switch som hjälper ANN att prediktera prestanda för båda fallen. Även denna parameter, precis som effekttregleringen, kan anta värdet ett (anti icing i drift) eller noll (anti icing avstängd). Denna switch består i sig av ett separat ANN, tränat med två utomhustillstånd (temperatur och relativ fuktighet), vilket innebär att användaren inte själv behöver ange hur vida anti icing är igång eller ej. För detta ANN är den relativa fuktigheten av stor vikt och därför är även den inkluderad bland indata i användargränssnittet som presenteras senare.

Bland utdata återfinns vissa likheter mellan modellerna, bl.a. så är eleffekt och rökgastemperatur fortfarande med. Heat rate är en utdata som inte finns med då den inte återfinns bland mätdata, istället beräknas verkningsgrad utifrån massflöde bränsle och producerad eleffekt som båda predikteras. En hel del ytterligare utdata har lags till då det är önskvärt att prediktera så mycket som möjligt för att kunna göra en mer djupgående analys av gasturbinens kondition. Det finns möjligheter att lägga till ytterligare utdata men antalet har begränsat inom detta projekt.

En grafisk jämförelse mellan den gamla modellen (baserad på syntetisk data) och den nya modellen (baserad på driftdata) finns i Figur 11 och Figur 12 där eleffekten samt avgastemperaturen (T_7) är plottade. De svarta punkterna representerar uppmätt data medan de gröna och röda representerar av ANN predikterade utdata. De gröna är predikterade av den senare ANN modellen. Eftersom den tidigare modellen använder last (procent av maxeffekt) som indata så har bara data för 100 % last kunnat användas i jämförelsen. Lasten är ingenting som registreras utan användaren ställer in önskad effekt som vid fullast innebär en effekt över den maximala effekten. Det näst vanligaste driftfallet för gasturbinen är 30 MW vilket i sin tur inte innebär att lasten är fixerad vid ett värde utan varierar med atmosfärstillstånden. Generellt i arbetet gäller att x-axeln anger antalet datapunkter, där varje datapunkt representerar fem minuter eftersom fem minuters medelvärde använts vid träning av modellerna. Exempelvis motsvarar 5200 datapunkter 26000 minuter, d.v.s. drygt 18 dygns drift.




Figur 11. Jämförelse av effekt prediktioner mellan tidigare ANN och nytt




Figur 12. Jämförelse av temperatur prediktioner mellan tidigare ANN och nytt

Som synes följer de predikterade värdena, från den nya modellen, de uppmätta värdena väl. Även om den förskjutning som den gamla modellen genererar hade eliminerats, och kurvorna lagts ovanpå varandra, så kan man ändå urskilja att den nya modellen ger bättre resultat. Det kan spekuleras i olika anledningar till detta, varav en är att i den nya modellen så finns atmosfärstryck med som indata och data som använts till jämförelsen är insamlad vid varierande atmosfärstryck. Vidare så finns det en anti icing switch med som indata i den nya modellen vilket självklart förbättrar resultatet [5]. Vid framtagning av den syntetiska datan togs ingen hänsyn till anti icing systemets effekter på prestanda. Dock ska det påpekas att de flesta trender går att spåra i resultaten från båda modellerna.

För att ytterligare rättfärdiga jämförelsen så innehåller de två följande figurerna, Figur 13 och Figur 14, samma plottar som Figur 11 och Figur 12 fast utan förskjutningen i y led. De, av den gamla modellen (baserad på syntetisk data), predikterade värdena (röda) läses nu av på den högra y axeln.




Figur 13. Jämförelse av effekt prediktioner mellan tidigare ANN och nytt utan y leds förskjutning




Figur 14. Jämförelse av temperatur prediktioner mellan tidigare ANN och nytt utan y leds förskjutning

Ur detta, samt med hjälp av tidigare erfarenheter av gasturbinsmodellering, kan ett antal intressanta slutsatser dras. Figur 14, innehållande t_7 prediktioner, visar mycket god överensstämmelse för båda modellerna (gammal och ny) de perioder då anti icing inte är i drift. Däremot kan man inte dra samma enkla slutsats för effekt prediktionerna i Figur 13. Detta beror på att effekten, så som många andra parametrar, är beroende av atmosfärstrycket. Hade atmosfärstrycket varit inkluderat som indata i den äldre modellen så hade den eventuellt visat samma goda resultat även för effekt prediktioner. Avgastemperaturen, tillskillnad från effekten, är inte beroende av atmosfärstrycket och de predikterade värdena från den gamla modellen blir därför bra (den gamla modellen innehöll inte atmosfärstrycket som indata). För att ytterligare illustrera detta så visas i Figur 15 och Figur 16 ett avsnitt där anti icing inte var i drift (punkt 4050-5200).



Figur 15. Jämförelse av effekt prediktioner mellan tidigare ANN och nytt utan y leds förskjutning och utan inverkan av anti icing




Figur 16. Jämförelse av temperatur prediktioner mellan tidigare ANN och nytt utan y leds förskjutning och utan inverkan av anti icing

I Figur 16 ser man att de gröna punkterna (nya modellen) och de röda punkterna (gamla modellen) följer varandra nästan exakt. Detta antyder att en modell baserad på syntetisk data kan ge samma goda resultat som en modell baserad på driftdata. För detta projektet gäller dock att driftdata har varit/är det som är lättast att få tag på, syntetiskt data kräver avancerade simuleringsverktyg samt expertkunnande för att ta fram. De ultimata målet med en sådan här modell är dock att kunna leverera den tillsammans med nya gasturbiner vilket inte är möjligt så länge man använder sig av driftdata eftersom den måste samlas in under lång period för att täcka alla möjliga driftsförhållande. Syntetisk data kan däremot tas fram i förväg med hjälp av Siemens simuleringsverktyg och på så sätt möjliggöra leverans av ANN modell tillsammans med gasturbinen. Varje gasturbin är i och för sig unik och vid prestandaprov så visar dom alla lite olika resultat, detta är dock bara en förskjutning och ursprungsmodellen bör kunna korrigeras enkelt. Detsamma gäller vid översyn av en gasturbin, t.ex. byte av brännkammare eller beskovling, som också kan förändra prestanda. Ytterligare fördel att träna med syntetisk data är att träning med, av olika anledningar (exempelvis drivande sensorer), korrupt data undviks.

4.3 Den nya ANN modellen för SGT800

Den slutliga gasturbinmodellen har fyra indata varav tre stycken, atmosfärstryck (p_{atm}), atmosfärstemperatur (t_{atm}), och effektregeringsparametern, matas in av användaren. Nio olika utdata predikteras av modellen, valda utifrån deras relevans men även modellerbarhet. Anti icing finns med bland indata men är ingenting som matas in av användaren utan predikteras av ett särskilt ANN. För att detta anti icing ANN ska fungera är det viktigt att relativ fuktighet ingår som indata, därför syns även denna med kursiv text i Tabell 2. Alternativt kan en liten funktion läggas till i Excel för att beräkna anti icing aktivitet. Anti icing går igång då temperaturen ligger mellan -5°C och $+5^{\circ}\text{C}$ samt luftfuktigheten överskrider 80%.



Figur 17. ANN struktur för gasturbinmodell

Tabell 2. In- och utdata samt dess enheter

Indata		Utdata	
Effektreglering	[1 eller 0]	Kompressor inloppstryck	[kPa]
Anti Icing	[1 eller 0]	Ledskenor, läge	[%]
Atmosfärstemperatur	[°C]	Temperatur avtappning 10	[°C]
Atmosfärstryck	[kPa]	Kompressor utloppstryck	[MPa]
Relativ fuktighet	[%]	Kompressor utloppstemperatur	[°C]
		Massflöde naturgas	[MJ/s]
		Massflöde turbin	[kg/s]
		Rökgastemperatur (t_7)	[°C]
		Eleffekt	[MW]

Som figurerna i 4.2 illustrerar så följer de predikterade värdena uppmätt data väl vilket också återspeglas i Tabell 3.


Tabell 3. Felfördelning vid prediktion av respektive utdata

Felfördelning	<1%	1-2%	2-4%	>4%
Kompressor inloppstryck	7239	0	0	0
Ledskenor, läge	6489	558	183	9
Temperatur avtappning 10	7142	90	6	1
Kompressor utloppstryck	7234	3	2	0
Kompressor utloppstemperatur	7223	16	0	0
Massflöde naturgas	6649	579	8	3
Massflöde turbin	7229	8	2	0
Rökgastemperatur (T_7)	7239	0	0	0
Eleffekt	7179	58	1	1


Här syns det att prediktionerna är mycket bra där de flesta av punkterna ligger under 1 % fel. Naturgasflödet är en parameter som utmärker sig vilket kan bero på två faktorer; den första är att bränslets värmevärde inte är inkluderat som indata till modellen, då den informationen inte fanns tillgänglig. Det andra är att flödet är funktion av ventillägen och ej uppmätt med t.ex. turbinhjul. Båda dessa faktorer bidrar till försämrade mät noggrannhet som återspeglas i större fel i ANN modellens prediktion. Även ledskenornas läge är en utdata som inte predikteras med samma säkerhet som övriga utdata. Detta har sin förklaring i regleringen av dessa vid delast inte är helt perfekt och detta återspeglas i driftdata. Detta betyder att vid ett bestämt driftförhållande kan läget på ledskenorna skilja från en gång till annan. ANN anger i sin tur ett sorts medelvärde i sina prediktioner och problemet med reglering blir tydligt.

För att ytterligare demonstrera ANNs förmåga så följer ett antal figurer där uppmätt data plottas tillsammans med av ANN predikterade värden. I dessa figurer är ledskenornas läge, kompressor utloppstryck samt producerad eleffekt plottade. För alla figurer gäller att uppmätta- samt predikterade värden (svart och grönt) avläses på vänster y-axel samt felet (blått) avläses på höger y-axel. Skalorna varierar från figur till figur. Det som särskiljer dessa plottar från varandra är att ledskenorna ligger konstant vid fullast, kompressor utloppstrycket varierar både vid fullast och 30 MW samt


eleffekten varierar vid fullast och är konstant vid det lägre lastfallet. Trots dessa skillnader så lyckas ANN med bravur följa de olika parametrarnas olika egenskaper.



Figur 18. ANN prediktioner jämfört uppmätta värden av ledskenor läge



Figur 19. ANN prediktioner jämfört uppmätta värden av kompressor utloppstryck




Figur 20. ANN prediktioner jämfört uppmätta värden av eleffekten

4.4 Användargränssnitt for gasturbinmodellen

Som nämnts tidigare används två ANN som sedan integreras till ett system. Ett ”huvud” ANN som predikterar GT prestanda samt en switch som anger anti icing aktivitet. I användargränssnittet ser användaren den integrerade modellen och behöver bara mata in omgivningstillstånd samt lasttillstånd (fullast eller 30 MW). Anti icing aktivitet syns som utdata i användargränssnittet och kan anta värdet ett eller noll och indikerar om anti icing är i drift eller inte. Alternativt kan man låta Excel beräkna om anti icing är igång eller ej eller vid online modellering skicka en signal från kontrollsystemet rakt in i modellen.

Användargränssnittet är framtaget i en Excel miljö, enligt Figur 21, då det är ett program alla har tillgång till. Hela bladet är lösenordsskyddat förutom de fyra gröna cellerna där indata ska matas in. Elverkningsgraden beräknas m.h.a. eleffekt och bränsleflöde.



Figur 21. Användargränssnitt gasturbinmodell

4.5 Framtida arbete

Det har visats att gasturbiner går utmärkt att modellera med ANN samt även att det finns möjligheter att göra det med syntetisk data vilket därmed öppnar dörren för att i framtiden kunna leverera ANN tillsammans med nya gasturbiner. Vidare forskning krävs självklart för att fullt kunna utvärdera möjligheterna. Den syntetiska datan, framtagen av Siemens, måste utökas med i ett första steg ytterligare indata för att kunna göra en rättvis jämförelse av utdata prediktioner. För att få modellen att fungera på en variation av gasturbiner måste, utöver de indata som diskuterats ovan, även hänsyn tas till bl.a. vilket bränsle som används, hur anti icing styrs samt bränslekvalitet. Målet är att i slutändan ha en modell som går att använda för alla gasturbiner (av en specifik modell). En sådan ANN modell kan användas för tillståndsovervakning av gasturbinen och eventuellt bidra till en övergång från tidsbaserat underhåll till konditionsbaserat. Viktigt att påpeka är att en sådan modell inte kan övervaka t.ex. individuella skovlar utan snarare gasturbinen i stort, vilket kan betyda bränslesystem, läckage mm.

5 Modellering av avgaspannan

Då hela systemet, Västhamnsverkets hybridanläggning, är i fokus för detta projekt är det av intresse inte bara att modellera gasturbinen utan även den efterföljande avgaspannan. Användningsområdet för denna modell är tänkt densamma som modellen för gasturbinmodellen, d.v.s. konditionsbestämning genom jämförelse av uppmätta data och de av ANN modellen predikterade. Samma baseline som användes vid gasturbinmodellering, 28/1 2006, har använts eftersom prestanda på avgaspannan i viss utsträckning anses bestämmas av skicket på gasturbinen.

Att modellera en avgaspanna är en helt ny erfarenhet inom detta SGC projekt. Flertalet möjligheter har undersökts innan en tillfredställande modell togs fram. Den slutgiltiga modellen är uppbyggd av sex indata, varav fyra är samma som för GT modellen, d.v.s. atmosfärs tryck- och temperatur, anti icing switch samt effektregerings switch. Anledningen till att använda samma indata som för GT modellen är att dessa kan användas för att prediktera massflöde rökgaser samt rökgastemperatur (se GT modell), just de parametrar som bestämmer hur mycket värme som kan extraheras från avgaspannan. Man kan säga att dessa fyra indata innehåller information om rökgaserna och att använda rökgasdata som indata är bara ett sätt att göra modellen mer invecklad samt svårare använd samtidigt som prestanda för modellen inte skulle förbättras. Skulle rökgasdata användas som indata är ett alternativ att vidarebefordra utdata från gasturbinmodellen direkt till avgaspannmodellen. Detta har två nackdelar, den första är att eventuella fel skulle fortplanta sig från gasturbinmodellen samt att offline simulering¹ vid separat användande av avgaspannmodellen skulle försvåras avsevärt eftersom rökgasdata är svåra att uppskatta. De två återstående indata består av retur- och framlednings temperaturer på fjärrvärmevattnet till fjärrvärme ekonomisern.


5.1 Driftdata och datafiltrering/behandling

Data som använts för denna modell är insamlad under samma period som för gasturbinen, d.v.s. februari till mars. Februari datan har använts för modelleringsarbetet ty det var under denna period gasturbinen kördes regelbundet. Vidare består även denna datan av fem minuters medelvärden. På samma sätt som för gasturbin modellen så har data undersökts för eventuella felaktigheter och därefter rensats. Efter filtrering återstod 6965 punkter som användes för träning, validering och test av ANN modellen.

5.2 ANN model för avgaspannan

Den slutliga modellen kan ses i Figur 22.

¹ Offline simulering innebär att ANN modellerna kan användas även när anläggningen inte körs. För att möjliggöra detta så är det lättast att enbart använda indata som vid alla tillfällen är kända, t.ex. utomhus tillstånd, alternativt indata som lätt kan uppskattas, t.ex. effektregering. Att använda indata som enbart är kända då anläggningen körs, t.ex. massflöde rökgaser, försvårar eller rent av omöjliggör offline simulering.



Figur 22. ANN struktur för avgaspannmodell (heat recovery steam generator)

Tabell 4. In- och utdata samt dess enheter

Indata		Utdata	
Anti Icing	[1 eller 0]	Massflöde fjärrvärme	[m ³ /h]
Atmosfärstryck	[kPa]	Massflöde matarvatten	[kg/s]
Atmosfärstemperatur	[°C]	Temperatur efter överhettare 1	[°C]
Effektreglering	[1 eller 0]	Temperatur efter överhettare 2	[°C]
Temperatur fjärrvärme retur	[°C]	Temperatur på utgående rökgaser	[°C]
Temperatur fjärrvärme fram	[°C]	Effekt fjärrvärme ekonomiser	[MW]

Utdata består av temperaturer, massflöden samt effekten som plockas ut ur fjärrvärme ekonomisern, allt som kan vara av intresse för användaren. Utdata har i stor utsträckning valts utifrån tillgänglighet och modellerbarhet. I framtida projekt finns det stora möjligheter, utifrån användarens specifikationer, att lägga till eller ta bort utdata. Felfördelning för respektive utdata visas i Tabell 5.


Tabell 5. Felfördelning vid prediktion av respektive utdata

Felfördelning	<1%	1-2%	2-4%	>4%
Massflöde fjärrvärme	3387	2225	1188	165
Massflöde matarvatten	5757	1019	165	24
Temperatur efter överhettare 1	6949	16	0	0
Temperatur efter överhettare 2	6965	0	0	0
Temperatur på utgående rökgaser	6481	464	17	3
Effekt fjärrvärme ekonomiser	4729	1711	453	72

Felen är generellt lite större än för gasturbinmodellen. Det kan spekuleras i många anledningar till detta, varav en skulle vara att ANN inte får all den information som behövs för att prediktera valda utdata. Med detta menas att ytterligare indata kanske ska läggas till. Flertalet tester med alternativa indata har dock genomförts utan större förbättring. Bland annat har tester med ventillägen, recirkulation samt bypass (syns i Figur 4), som styr fjärrvärme flödet utförts. Vidare, som nämdes innan, så är ett av målen med modellerna att de ska fungera även offline vilket i sin tur begränsar möjligheterna vid val av indata.


Ett exempel på detta är att temperaturen på fjärrvärme vattnet precis innan och efter ekonomisern kan förbättra prediktionerna en aning men dessa parametrar är varken kända eller särskilt lätta att uppskatta. Hur som helst kan en mer djupgående analys för att reda ut alla samband vara på sin plats.

En annan anledning till de lite större felen kan vara att mätningarna inte är lika noggranna, alternativt pålitliga, som de gjorda i gasturbinen. Detta gäller framförallt massflöden som alltid är svåra att mäta i en kommersiell anläggning. Figur 23 visar dock att trots lite större fel så har ANN inga problem att följa trender även för den mest svår predikerade parametern (av att döma från Tabell 5) som är vattenflöde genom fjärrvärme ekonomisern.




Figur 23. ANN prediktioner jämfört uppmätta värden av vattenflöde genom fjärrvärme ekonomisern

I figuren nedan syns det att de uppmätta (svarta) punkterna är relativt spridda i y led vilket kan vara en indikation på att de inte är så pålitliga och rentav bidrar till ökade fel för ANN modellen.



Figur 24. ANN prediktioner jämfört uppmätta värden av matarvattenflöde

Temperaturen efter överhettare 2, innan de-superhetern, är en av de utdata som kan predikteras med mycket hög noggrannhet, se Figur 25. Lägga märke till fel skalan (högra y axeln) och hur endast ett fåtal punkter överstiger 0.25 % fel.




Figur 25. ANN prediktioner jämfört uppmätta värden av ångtemperatur efter överhettare 2

Överlag så är resultatet av modelleringen tillfredställande och ANN visar sin utmärkta förmåga att hitta samband mellan indata och utdata.

5.3 Användargränssnitt för avgaspannmodellen

Avgaspannmodellen är integrerad i samma Excel arbetsbok som gasturbinmodellen, allt för att förenkla för slutanvändaren. Detta innebär att indata som matas in för gasturbinmodellen skickas vidare till avgaspannmodellen (eftersom vissa indata är gemensamma) vilket minskar komplexiteten samt det arbete som krävs för att använda den slutliga modellen. Som figuren visar så är det enbart två ytterligare indata (gröna celler) som behövs för denna modell, nämligen retur- och framledningstemperatur på fjärrvärme vattnet. Vidare så är även alla sensor koder, på in- och utdata givna i en tabell för att underlätta för användaren.



Figur 26. Användargränssnitt för avgaspannmodell

5.4 Framtida arbete

Tillskillnad från gasturbinen och ångturbinen (i viss utsträckning) så sker förändringar i avgaspannans drift inte särskilt snabbt. Detta beror på att själva värmeöverföringsprocessen i pannan inte är direkt utan tar sin tid. Detta kan vara ett incitament att använda t.ex. tim medelvärden alternativt träna ett ANN med tidsförskjutning mellan indata och utdata.

6 Modellering av ångpannan

Ångpannmodellen skiljer sig från de andra modellerna i den bemärkelsen att en indata måste beräknas före själva träningen av ANN. Eftersom ingen riktig mätning på bränsle flödet finns tillgänglig så har andra termodynamiska storheter använts för att beräkna flödet. Beräkningarna grundas på en värmebalans över pannan och entalpier har hämtats ur elektroniska ångtabeller samt ett konstant värmevärde har antagits. Följande ekvationer har använts [6].

$$\dot{Q}_{\text{panna}} = \dot{m}_{\text{ånga}} \cdot (h_{\text{ånga}} - h_{\text{vatten}})$$

$$P_{\text{bränsle}} = \frac{\dot{Q}_{\text{panna}}}{\eta_{\text{panna}}}$$

$$\dot{m}_{\text{bränsle}} = \frac{P_{\text{bränsle}}}{H_u}$$

$$\eta_{\text{panna}} = \frac{t_{\text{max}} - t_{\text{rg efter LUFÖ}}}{t_{\text{max}} - t_{\text{atm}}}$$

$$H_u = 17164 \text{ kJ/kg}$$


Entalpierna har hämtats vid rådande tryck och temperatur före och efter pannan för att sedan användas för att beräkna den aktuella effekten i pannan. Istället för att anta ett konstant värde för verkningsgraden har den beräknats i varje punkt med hjälp av eldstadstemperaturen, temperaturen efter luftförvärmaren samt atmosfärstemperaturen. Denna verkningsgrad används i sin tur för att beräkna effekten för det tillförda bränslet. Med ett antaget konstant värmevärde kan sedan massflödet bränsle beräknas.

6.1 Driftdata och datafiltrering/behandling

Data som använts för denna modell är insamlad under samma period som för de andra modellerna, d.v.s. februari till mars. Februari datan har använts för modelleringsarbetet. Vidare består även denna datan av fem minuters medelvärden. På samma sätt som för de andra modellerna så har data undersökts för eventuella felaktigheter och därefter rensats. Efter filtrering återstod 6825 punkter som användes för träning, validering och test av ANN modellen.

6.2 ANN modell för ångpannan

Den slutliga modellen har endast 3 indata och 2 utdata. Försök med att prediktera ytterligare utdata, så som rökgastemperatur- och flöde samt emissioner, har gjorts men mer tid behöver läggas på detta för att fullt kunna evaluera möjligheterna. Vid modellering av pannan har fokus därför legat på de utdata som behövs som indata till ångturbinmodellen, d.v.s. massflöde och temperatur på ångan.




Figur 27. ANN struktur för ångpannmodell

Tabell 6. In- och utdata samt dess enheter


Indata		Utdata	
Massflöde biobränsle	[kg/s]	Massflöde ånga	[kg/s]
Atmosfärstemperatur	[°C]	Temperatur ånga	[°C]
Temperatur matarvatten efter HTFV	[°C]		

Tabell 7. Felfördelning vid prediktion av respektive utdata

Felfördelning	<1%	1-2%	2-4%	>4%
Massflöde ånga	5119	1486	211	9
Temperatur ånga	5597	1136	87	5



Figur 28. ANN prediktioner jämfört uppmätta värden av ångtemperatur



Figur 29. ANN prediktioner jämfört uppmätta värden av massflöde ånga


Av siffrorna att döma så är temperatur prediktionerna aningen bättre än massflödes prediktionerna. När man tittar på plottarna i Figur 28 och Figur 29 så ser man tvärt emot vad siffrorna antyder att ANN har lättare att följa trender i massflödet. Eftersom den

procentuella förändringen av massflödet vid drift är mycket större så kan resultatet bli på detta viset. Detta är därför en bra illustration varför det är viktigt att göra jämförelser dels med t.ex. felfördelning men även grafiskt.

Det finns stora möjligheter till vidareutveckling och förbättring av denna modell genom att t.ex. lägga till ytterligare indata. Ett exempel på indata som kan förbättra ANNs prestanda är temperaturen i eldstaden. Detta är såklart omöjligt om modellen ska fungera för offline simulering men det är något att ha i åtanke när det blir dags att utveckla ett online system. Därmed inte sagt att modellerna inom ramen för detta arbete inte fungerar online.

6.3 Användargränssnitt för ångpannmodellen

Massflödet biobränsle är den enda indata som behöver matas in av användaren eftersom atmosfärstemperaturen redan matats in för gasturbinmodellen. Temperaturen på matarvattnet efter HTFV predikteras av ångturbinmodellen och skickas automatiskt vidare till pannmodellen.



Figur 30. Användargränssnitt för ångpannmodell

6.4 Framtida arbete

Som nämnts så finns det sätt att förbättra denna modellen genom att t.ex. lägga till ytterligare indata. En annan intressant approach hade varit att med hjälp av värme- och massbalans program och modeller över pannan baklänges beräkna bränsleflödet och på så sätt undersöka om det går att få bättre värden på denna.

7 Modellering av ångturbinen

Det finns sedan tidigare ANN modeller av Västhamnsverkets ångturbin för prediktion av eleffekten. I den första modellen användes sju indata: totalt massflöde ånga, temperatur på fram- och retur ledning av fjärrvärme, massflöde fjärrvärme, tryck- och temperatur före högtryckförvärmaren samt temperaturen på avtappningen till högtrycksförvärmaren. I det andra försöket inkluderades ytterligare indata, bl.a. tryck efter Cutrissteg och trycket i kondensatorerna. Denna andra modell hade hela sjutton indata. Båda modellerna hade producerad eleffekt som utdata. [3][6]

Ett av målen i dagsläget har varit att förenkla alla ANN modeller så lång det går samt att möjliggöra offline användande. Med detta i åtanke har en ny modell med endast fyra indata skapats. Värt att nämna är att alla tre modeller är baserade på driftsdata dock med skillnaden att vid modellering av den senare så har fem minuters medelvärden använts och tidigare användes tim medelvärden. Det är svårt att avgöra vad som är bäst men förloppet i ångturbinen anses, precis som för gasturbinen, vara relativt snabbt, d.v.s. om ångdata (indata) ändras så hinner detta återspeglas på utdata (effekten) under fem minuter.

7.1 Driftdata och datafiltrering/behandling

Precis som för tidigare modeller så har data under perioden februari använts, allt för eliminera eventuella fel som kan uppstå om data från olika tidsperioder skulle användas, orsakade t.ex. av förändringar i anläggningens prestanda. En stor mängd parametrar fanns tillgängliga, som antyds ovan (17 indata i den mest komplexa modellen) och mycket av arbetet har gått ut på att validera vilka som har störst betydelse för nätverket. Detta görs genom att individuellt ta bort var och en från träningsmängden samt jämföra resultatet efter träning. Utöver detta arbete ska även ytterligare indata undersökas. Efter filtrering återstod 6855 punkter som användes för träning, validering och test av ANN modellen.

7.2 Jämförelse mellan tidigare ANN modeller och ny

Tabell 8 sammanfattar de tre modellernas struktur med avseende på indata samt medelfel för prediktionerna, modellerna benämns med 1, 2 och 3, namngivna i kronologisk ordning.


Tabell 8. Jämförelse mellan ANN modeller [3][6]

ANN modell	Antal indata	Medelfel för elprediktioner [%]
1	7	1.26
2	17	0.25
3	4	0.28

Modell 2 och 3 är i det närmsta jämförbara i prestanda så att rättfärdiga användandet av 17 indata istället för 4 känns omotiverat. Att ha 17 indata är inte bara tidskrävande, det ökar komplexiteten av modellen och många av parametrarna är väldigt svåra att uppskatta. Denna modell var dock tänkt för online modellering, d.v.s. att den matas med data direkt från verket, men även om så är fallet så bör antalet indata minimeras eftersom modellens känslighet ökar ju fler sensorer den är beroende av. I modell 1 har uppenbarligen någon indata parameter förbisetts vilket bidrar till mycket sämre prestanda, alternativt så finns det fler mätpunkter i dagsläget.

7.3 Den nya ANN modellen för ångturbinen

Vid modelleringen av pannan insågs det att temperaturen på matarvattnet efter högtrycksförvärmaren är av stor vikt för att öka noggrannheten för modellen. Eftersom denna temperatur kan vara mycket vanskelig att själv uppskatta eftersom den indirekt beror på hur mycket bränsle som matas in i pannan så blev lösningen att låta ångturbin modellen prediktera temperaturen. En komplett lista på in- och utdata samt dess enheter återfinns nedan.



Figur 31. ANN struktur för ångturbinmodell (ångcykelmodell)


Tabell 9. In- och utdata samt dess enheter

Indata		Utdata	
Massflöde ånga HRSG	[kg/s]	Eleffekt	[MW]
Massflöde ånga panna	[kg/s]	Temperatur matarvatten efter HTFV	[°C]
Temperatur ånga panna	[°C]		
Temperatur framledning fjärrvärme	[°C]		

Tabell 10. Felfördelning vid prediktion av respektive utdata

Felfördelning	<1%	1-2%	2-4%	>4%
Eleffekt	6740	114	1	0
Temperatur matarvatten efter HTFV	6848	7	0	0


Som Tabell 10 visar är prediktionerna mycket bra för båda utdata parametrarna, detta exemplifieras ytterligare i figuren nedan som visar prediktioner av eleffekten.



Figur 32. ANN prediktioner jämfört uppmätta värden av eleffekt

7.4 Användargränssnitt för ångturbinmodell

Eftersom massflödet ånga från avgaspannan predikteras av avgaspannmodellen så behövs det inte skrivas in för hand utan det skickas automatiskt vidare. Samma sak gäller massflöde och temperatur på ångan från pannan som predikteras av ett separat ANN över ångpannan och även det skickas vidare. Det som däremot ska skrivas in för hand är temperaturen på framledningen av fjärrvärmevattnet (grön cell).




Figur 33. Användargränssnitt för ångturbinmodell

7.5 Framtida arbete

Som för flera av de andra modellerna så finns det möjligheter att utöka antal utdata utifrån användarens specifikationer.

8 Koppling/Samverkan mellan ANN modeller

Viktigt att påpeka är att alla modeller går att använda var och en för sig men för att skapa en överskådlig modell för hela hybridanläggningen samt kunna utnyttja vissa synergieffekter har ett nätverk utvecklats. Detta har ett antal fördelar så som att antalet indata som behöver anges minimeras samtidigt som en förståelse för sambandet mellan de olika delsystemen skapas. En nackdel kan vara att noggrannheten försämras eftersom fel kan fortplantas och eventuellt förstärkas mellan modellerna. Figur 34 visar hur utdata från vissa modeller fungerar som indata till andra. Gasturbin- samt avgaspannmodellen är inte beroende av några andra modeller och därför blir prestanda för dessa modeller samma som presenterats tidigare. Mer osäkert blir det för ångpann- och ångturbinmodellen eftersom de inte bara är beroende av varandra utan även av avgaspannmodellen. Eftersom pann- och ångturbinmodeller utbyter information åt båda hållen så krävs en iterativ process för att komma fram till en lösning. Matarvattentemperaturen efter HTFV som predikteras av ångturbinmodellen behövs av pannmodellen för att prediktera ångdata samtidigt som ångdata behövs av ångturbinmodellen för att prediktera matarvattentemperaturen. Som tur är finns det färdiga lösningar för iterationsprocesser i Excel och det är ingenting användaren vare sig märker av eller behöver bry sig om.



Figur 34. ANN modeller sammankopplade i nätverk

En undersökning av noggrannheten för alla utdata har gjorts med slumpvis utvalda indata, vid varierande driftsförhållande, vart på ett medelfel beräknats. Detta medelfel är inte baserat på lika många punkter som de medelfel som tidigare beräknats för respektive modell och är därmed inte statistiskt säkerställt på samma sätt, de duger dock för att ge en indikation på vilka utdata som försämras och vilka som är oberörda. Följande tabeller erhöles.

Tabell 11. Jämförelse av medelfel för utdata från gasturbinmodellen

Utdata	$p_{k,in}$	Led	$t_{avt,10}$	$p_{k,ut}$	$t_{k,ut}$	m_{NG}	m_{turbin}	t_7	P_{el}
Medelfel sammankopplat [%]	0.03	0.40	0.21	0.18	0.11	0.45	0.19	0.06	0.16
Medelfel individuellt [%]	0.03	0.32	0.26	0.17	0.18	0.48	0.15	0.05	0.21

Tabell 12. Jämförelse av medelfel för utdata från avgaspannmodellen

Utdata	$m_{fj.v. eco}$	$m_{ånga, HRSG}$	$t_{OH 1}$	$t_{OH 2}$	$t_{rökgaser, ut}$	$P_{fj.v. eco}$
Medelfel sammankopplat [%]	1.36	0.57	0.07	0.10	0.47	0.90
Medelfel individuellt [%]	1.26	0.61	0.09	0.09	0.45	0.88

Tabell 13. Jämförelse av medelfel för utdata från ångpannmodellen

Utdata	$t_{ånga, panna}$	$m_{ånga, panna}$
Medelfel sammankopplat [%]	0.79	0.79
Medelfel individuellt [%]	0.58	0.70


Tabell 14. Jämförelse av medelfel för utdata från ångturbinmodellen

Utdata	P_{el}	$t_{mava e. HTFV}$
Medelfel sammankopplat [%]	1.22	0.30
Medelfel individuellt [%]	0.29	0.15

Genom att studera tabellerna och jämföra medelfel för gasturbin- och avgaspannmodellen så kan slutsatser dras om att den utvalda datamängden var representativ eftersom medelfelen följer varandra mycket nära. Med detta i åtanke kan tabellerna innehållande medelfel för pann- och ångturbinmodell analyseras. Som förväntat är felen för dessa modeller aningen högre när de samkörs i ett nätverk. Särskilt tydligt blir det på elprediktionerna som ökar från låga 0.29% till 1.22%, därmed inte sagt att 1.22 % är högt i något avseende. Just denna parameter är extremt känslig för förändringar i ångflöde samt ångtemperatur och eftersom just dessa har ett allmänt högre fel, p.g.a. av diverse brister i pannmodellen, så lyser detta genom i resultatet. Ångturbinmodellen är med andra ord mycket bra så länge man kan lita på indata, d.v.s. ångflöde samt ångtemperatur. Nu är det upp till användaren om han/hon accepterar ett större medelfel eller inte. Det finns ett antal alternativa åtgärder för problemet varav en enkel lösning är att köra modellen individuellt och mata den med ångdata signaler från anläggningen. En vidareutveckling av pannmodellen är också ett alternativ, där ett förslag är att använda ett värme- och massbalansprogram för att ”bakvägen” beräkna bränsleförbrukningen och på det viset få mer korrekta värden på densamma.

8.1 Användargränssnitt för hela hybridanläggningen

Figur 35 visar hur alla modeller är integrerade i samma Excel dokument. Varje modell representeras av en egen flik, inringat i rött (i detta fall är avgaspannmodellen vald). Den aktuella modellen kan dessvärre inte hantera fallet då gasturbinen är avstängd, detta är något som kan bli aktuellt i framtida modeller.



Figur 35. Gemensamt användargränssnitt

Som nämnts flertalet gånger i texten så har ett av målen varit att modellen (modellerna) ska kunna användas offline, men det har inte diskuterats i vilket syfte. Ett enkelt exempel är att använda modellen vid planering av driften eftersom parametrar som bränsleflöde och producerad eleffekt går att prediktera. Ett annat exempel är att använda modellen i utbildningssyfte då den är väldigt lättanvänd och ger en bra känsla för hur de olika delsystemen hänger ihop.

9 Resultatredovisning

Nedan redovisas en sammanfattning av resultaten för respektive modell, tabellerna är hämtade från tidigare avsnitt. Tabellerna ska tolkas som ANNs förmåga att prediktera utdata. T.ex., av 7239 tillgängliga punkter så predikterar ANN kompressor utloppstrycket med mindre än 1 % fel vid varje tillfälle.

Tabell 15. Felfördelning av prediktioner från gasturbin modellen

Felfördelning	<1%	1-2%	2-4%	>4%
Kompressor inloppstryck	7239	0	0	0
Ledskenor, läge	6489	558	183	9
Temperatur avtappning 10	7142	90	6	1
Kompressor utloppstryck	7234	3	2	0
Kompressor utloppstemperatur	7223	16	0	0
Massflöde naturgas	6649	579	8	3
Massflöde turbin	7229	8	2	0
Rökgastemperatur (T_7)	7239	0	0	0
Eleffekt	7179	58	1	1

Tabell 16. Felfördelning av prediktioner från avgaspannmodellen

Felfördelning	<1%	1-2%	2-4%	>4%
Massflöde fjärrvärme	3387	2225	1188	165
Massflöde matarvatten	5757	1019	165	24
Temperatur efter överhettare 1	6949	16	0	0
Temperatur efter överhettare 2	6965	0	0	0
Temperatur på utgående rökgaser	6481	464	17	3
Effekt fjärrvärme ekonomiser	4729	1711	453	72

Tabell 17. Felfördelning av prediktioner från ångpannmodellen

Felfördelning	<1%	1-2%	2-4%	>4%
Massflöde ånga	5597	1136	87	5
Temperatur ånga	5119	1486	211	9

Tabell 18. Felfördelning av prediktioner från ångturbinmodellen

Felfördelning	<1%	1-2%	2-4%	>4%
Eleffekt	6740	114	1	0
Temperatur matarvatten efter HTFV	6848	7	0	0

Utöver modellering av respektive delsystem har även noggrannheten undersökts för alla delsystem sammankopplade i ett nätverk, d.v.s. utdata från en modell agerar indata till en annan o.s.v. Detta visade på att fel för en modell kan fortplantas och förstärkas i nästa vilket syntes särskilt tydligt för ångturbinmodellen där felet för ökade från 0.29% till 1.22% för eleffekten.

Vad som mer kan tolkas som resultat är användargränssnittet som med fördel togs fram i en Excel miljö. Detta består av 4 individuella modeller av respektive delsystem som sammankopplats till ett stort system för att återspegla hela hybridanläggningen.

Jämförelsen av de två gasturbinmodellerna är också ett stort nummer i detta arbete. Det är första gången det har visats att en modell baserad på syntetisk data kan ge samma goda resultat som en baserad på driftdata. Modellerna är jämförbara då gasturbinen körs på fullast och då anti icing är avstängd. Just här visades det på en förträfflig överensstämmelse mellan de två modellerna.

9.1 Erfarenheter från modelleringsarbetet

För att skapa modeller så som de som beskrivits i denna rapport så krävs det en del förkunskaper samt att en hel del arbete läggs ner, några viktiga områden belyses här näst. Modelleraren bör vara insatt i/ha kunskap om:

- ANNs uppbyggnad och funktion
- datafiltrering och datahantering i förslagsvis Excel
- programvara så som NeuroSolutions (alternativt Matlab ANN toolbox)
- visual basic för efterbehandling av nätverken
- systemet som ska modelleras

I detta projekt har en stor del (om inte den största) av tiden lagts på förståelse av systemet, d.v.s. hybridanläggningen.

Att sätta sig in i dessa olika delar kan vara tidskrävande men om modelleraren har god kunskap i dom alla så kan själva modelleringsarbetet gå relativt snabbt med förutsättningen att data finns tillgänglig. Dock måste det påpekas att lära sig detta på egen hand kan vara väldigt svårt och ineffektivt, därför rekommenderas någon form av kurs alternativt handledning från kunnig person.

10 Resultatanalys

Gasturbinmodellen samt ångturbinmodellen står ut med extremt bra träffsäkerhet i prediktionerna. Detta kan ha att göra med att alla modeller är tränade med fem minuters medelvärde och eftersom alla system som är baserade på värmeöverföring, avgaspanna och ångpanna, generellt är trögare vilket resulterar i större fel för dessa. Det kan även bero på att mätningar gjorda för exempelvis gasturbinen förmodligen är av högre noggrannhet än för pannan.

För gasturbinmodellen så är det två utdata som predikteras med aningen sämre precision, bränsleflödet och ledskenornas läge. Bränsleflödet beräknas som funktion av ventilläge vilket är en felkälla i sig. Samtidigt kompenseras flödet för värmevärdet, förhöjt värmevärde ger mindre flöde och tvärtom. Bränslet som används i Västhamnsverket är väldefinierat och varierar inte mycket men små fluktuationer går inte att undvika. Ledskenornas läge är konstant vid fullast men vid dellast så regleras dom efter atmosfärstillstånden. Det finns en fördröjning i återkopplingen mellan effektuttag och ledskenornas position vilket leder till spridning av uppmätt data vilket återspeglas i ANN prediktionernas noggrannhet.

Avgaspannmodellen karakteriseras av att flödes prediktionerna har större fel än temperatur prediktionerna. En anledning till detta kan vara att flödesmätningar i allmänhet är svårare att göra och därför inte är lika pålitliga. Det är viktigt att påpeka att prediktionerna aldrig kan bli bättre än noggrannheten i den tillgängliga datan, vilket gäller för alla modeller.

Prediktionerna från ångpannmodellen har i ”dessa sammanhang” ganska stora fel i prediktionerna vilka antagligen kan härledas direkt till att massflödet av biobränsle måste beräknas innan ANN kan tränas. Detta är en stor felkälla som hade kunnat undvikas om det hade funnits bättre mätningar på massflödet.

Generellt gäller att det finns stora möjligheter att utöka listan av utdata från de olika modellerna utifrån användarens specifikationer. Utdata till modellerna i detta projekt är valda utifrån tillgänglighet och modellerbarhet. Man kan se modellerna som exempel på vad som är möjligt att modellera och ha dessa som grund för vidareutveckling.

En risk med modeller baserade på driftdata är att eventuella sensorfel bakas in i modellerna. Beroendet av bra mätningar och pålitliga sensorer är därför stort. Detta är en av anledningarna till att användning av simulerade data för ANN modellering är av intresse.

När modellerna kopplas samman i ett nätverk är det av extra vikt att utdata predikteras med så små fel som möjligt eftersom fel fortplantas och förstärks, vilket kunde konstateras i fallet med eleffektuttag från ångturbinen. Eftersom felet för eleffekten från ångturbinen ökade så markant kan det vara aktuellt att friställa modellerna från varandra. Detta leder tyvärr till att vissa synergieffekter, som diskuterats i tidigare avsnitt, går förlorade.

Jämförelse mellan en gasturbinmodell med syntetisk data och en med driftdata visade att det är möjligt att basera ANN modeller på syntetisk data för leverans tillsammans med nya gasturbiner. Denna undersökning är dock inte helt färdigställd och behöver kompletteras med utförligare simuleringsdata så att jämförelsen kan innefatta både varierande last och anti icing aktivitet.

11 Slutsatser

Resultaten visar att:

- ANN modellering med bra noggrannhet av olika delsystem med varierande egenskaper är möjligt.
- ANN modeller av delsystem kan med fördel integreras till ett sammanhängande system vid modellering av stora komplexa anläggningar
- ANN modell över anläggningen kan presenteras i användarvänliga gränssnitt som varken kräver speciella programmiljöer eller specialkunskaper av användaren.
- utvecklade ANN modeller, baserade på verklig driftdata, kan användas för simulering av anläggningen vid driftplanering och i utbildningssyfte.
- tidsåtgång för varje beräkningssteg är så kort att anläggningsövervakning i realtid är möjligt med hjälp av ANN.
- det finns potential för utveckling av ANN modeller baserade på syntetisk data vilket underlättar heltäckande modellering av möjliga driftområden utan tillgång till mätdata

Det bör även påpekas att:

- slutprodukten är inte minneskrävande och ställer inte några höga krav på datorkapacitet
- eftersom kraftproducenter ofta använder Excel för insamling av data så underlättas integrering av användargränssnittet i deras system
- då uppmätta och predikterade systemparametrar kan visas sida vid sida underlättas övervakning av anläggningen för operatörerna

12 Diskussion

Att använda ANN modeller i kraftverkssammanhang är en relativt ny företeelse. ANN "tävlar" mot traditionella ekvationsbaserade program/system baserade på bl.a. värme- och massbalanser. Fördelarna med ANN är bl.a. att:

- Samband som är svåra att uttrycka fysikaliskt modelleras i ANN genom detektering av statistiska samband mellan in- och utdata.
- Modelleringsarbetet går relativt snabbt, förutsatt att detaljerad kunskap om systemets funktionssätt finns hos modelleraren. Tillgång till mätdata vid varierande driftstillstånd är dock en förutsättning för ANN modellering.
- Slutprodukten är väldigt lättanvänd samt fungerar i realtid
- Slutprodukten kan implementeras i valfri programmiljö, t.ex. MS Excel.

13 Förslag till fortsatt forskningsarbete

Under respektive modellerings avsnitt, 4 - 7, har några framtida forskningsområden identifierats, i detta avsnitt presenteras de tre viktigaste och största områdena inom vilka fortsatt forskningsarbete starkt rekommenderas.

Det första området härrör från jämförelsen mellan gasturinmodellerna, baserade på driftdata respektive syntetisk data (avsnitt 4.2). Resultaten i denna rapport visar tydligt att det finns potential för ANN att tränas med syntetisk data vilket öppnar möjligheten att i framtiden leverera ANN tillsammans med nya gasturbiner. För gasturbintillverkarna är det högt eftertraktat att kunna leverera någon form av övervakningssystem tillsammans med sina nya gasturbiner och ANN har potential att fylla det tomrummet. För att det ska vara möjligt att göra en fullständig utvärdering av dessa möjligheter krävs dock först att simuleringsdata från Siemens utökas till att omfatta fler indata och utdata. Exempel på ytterligare indata är atmosfärstryck, anti icing och bränslesammansättning. Den nya datan används därefter för träning av ett nytt ANN, vart på en komplett jämförelse kan utföras vid alla möjliga driftförhållande.

Det andra området är en vidareutveckling av användargränssnittet och på samma gång de ingående modellerna. Önskvärt är att användargränssnittet kopplas upp mot Västhamnsverkets egna system så att det på så vis kan ta emot signaler i realtid (online). Vid användande av ANN modeller online finns inget krav på att indata ska vara kända, alternativt lätta att uppskatta, eftersom indata kommer direkt från kraftverkets sensorer. Detta betyder att ytterligare indata som kan förbättra ANN modellernas prestanda kan läggas till. Ett onlinesystem kan användas för tillståndsovervakning som i sin tur leder till effektivare underhåll och ökad tillgänglighet. En intressant utveckling hade varit att inkorporera ekonomiska beräkningar i användargränssnittet som t.ex. beräknar när det är lönsamt att utföra en kompressortvätt, baserat på bl.a. bränslepris, elpris och degraderingens omfattning.

Sensor validering var ett moment som utelämnades i detta projekt eftersom tiden var knapp och omfattningen på ett sådant arbete är i samma storleksordning som det utförda. Sensor validering används, som namnet antyder, för att validera/bedöma ifall sensorer fungerar korrekt och ANN har visat sig vara ett lämpligt verktyg för detta ändamål. Kort beskrivet fungerar så att indata och utdata till ett ANN är desamma. På detta viset är utdata beroende dels av sig själv men även av andra parametrar. Skulle ett fel uppstå i en sensor så kan det detekteras genom beräkning av konfidens nivån. [5]

14 Litteraturreferenser

- [1] Arriagada J; "Introduction of Intelligent Tools for Gas Turbine Based, Small-Scale Cogeneration", Licentiate avhandling, Lund december 2001
- [2] Arriagada J; "On the Analysis and Fault-Diagnosis Tools for Small-Scale Heat and Power Plants", Doktors avhandling, Lund december 2003
- [3] Arriagada J, Assadi M, Genrup M, Karlsson A, Klingman J, Torisson T; "Uppföljningsprojekt GTX100 i Helsingborg", Lund januari 2005
- [4] Assadi M; "Methods and Tools for Analysis and Optimization of Power Plants", Doktors avhandling, Lund 2000
- [5] Fast M; "Artificial Neural Networks for Gas Turbine Modelling and Sensor Validation", Examensarbete, Lund december 2005
- [6] Kaiadi M; "Artificial Neural Networks Modelling for Monitoring and Performance Analysis of a Heat and Power Plant", Examensarbete, Lund januari 2006
- [7] Kröse B, van der Smagt P; "An Introduction to Neural Networks", 1996
- [8] Olausson P; "Tools for Environmental Design and Operation of Heat and Power Plants", Licentiate avhandling, Lund december 2001
- [9] Olausson P; "On the Selection of Methods and Tools for Analysis of Heat and Power Plants", Doktorsavhandling, Lund december 2003.



Hemsida www.sgc.se • epost info@sgc.se
