# Rapport SGC 241

# Artificiella neuronnät för gasturbinövervakning



Magnus Fast & Marcus Thern Institutionen för Energivetenskaper, Lunds Universitet

Oktober 2011

Rapport SGC 241 •1102-7371 • ISRN SGC-R-241-SE



© Svenskt Gastekniskt Center AB

# **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 dylikt 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 Energikoncernen AB (publ), Göteborg Energi AB, och Öresundskraft AB.

Följande parter har gjort det möjligt att genomföra detta utvecklingsprojekt:

Energimyndigheten Siemens Industrial Turbomachinery AB Göteborg Energi AB Öresundskraft AB

SVENSKT GASTEKNISKT CENTER AB

All

Jörgen Held

# Sammanfattning

Genom tillgänglig historisk driftdata från gasturbiner kan snabba, exakta, lättanvända och pålitliga modeller tas fram. Dessa modeller kan användas för övervakning av gasturbiner och assistera i en övergång från dagens tidsbaserade underhåll till ett tillståndsbaserat underhåll. För slutanvändaren innebär det, eftersom endast driftdata behövs, att de enkelt kan utveckla sina egna verktyg oberoende av tillverkaren.

Traditionellt byggs denna typ av modeller upp med fysikaliska samband för t.ex. massa, energi och impulser. Att ta fram en modell med fysikaliska samband är ofta arbetsamt och kräver sekretessbelagd information som slutanvändaren inte har tillgång till.

Forskningen har visat att genom ta fram modeller med hjälp av driftdata så kan en väldigt hög modellnoggrannhet uppnås. Vid implementering av dessa modeller i ett kraftverks datasystem kan gasturbinens prestanda övervakas i realtid. Detta kan underlätta att upptäcka fel på ett tidigt stadium och, om så behövs, stoppa gasturbinen innan större skador uppstår. För kraftverksägaren innebär detta att gasturbinens pålitlighet ökar genom att underhållsbehovet minimeras och stilleståndstiden minskar. Det innebär också att man hela tiden har ett mått på gasturbinens generella status, med avseende på t.ex. degradering, och kan utifrån det planera sina serviceintervall.

Verktyget som använts kallas artificiella neuronnät (ANN), ett samlingsnamn på ett antal algoritmer för informationsbehandling som försöker efterlikna nervcellernas funktion. Precis som riktiga nät av nervceller i en hjärna så har dessa artificiella neuronnät förmågan att lära sig. I detta fall är neuronnäten tränade att efterlikna beteendet av gasturbiner genom att introducera dem för data från riktiga gasturbiner. Efter det att ett neuronnät är upplärt så representerar det en mycket exakt modell av den gasturbin det är tränat att efterlikna.

# **Summary**

Through available historical operational data from gas turbines, fast, accurate, easy to use and reliable models can be developed. These models can be used for monitoring of gas turbines and assist in the transition from today's time-based maintenance to condition based maintenance. For the end user this means that, because only operational data is needed, they can easily develop their own tools independent of the manufacturer.

Traditionally these types of models are constructed with physical relations for e.g., mass, energy and momentum. To develop a model with physical relations is often laborious and requires classified information which the end user does not have access to.

Research has shown that by producing models using operational data a very high model precision can be achieved. When implementing these models in a power plant computer system the gas turbine's performance can be monitored in real time. This can facilitate fault detection at an early stage, and if necessary, stop the gas turbine before major damage occurs. For the power plant owner, this means that the gas turbine reliability is increased since the need for maintenance is minimized and the downtime is reduced. It also means that a measure of the gas turbine's overall status is continuously available, with respect to e.g. degradation, which helps in the planning of service intervals.

The tool used is called artificial neural networks (ANN), a collective name for a number of algorithms for information processing that attempts to mimic the nerve cell function. Just like real networks of neurons in a brain, these artificial neural networks have the ability to learn. In this case, neural networks are trained to mimic the behavior of gas turbines by introducing them to data from real gas turbines. After a neural network is trained it represents a very accurate model of the gas turbine that it is trained to emulate.

# Innehåll

Sa	ammanfattningi						
Sı	Summaryii						
Ν	Nomenklatur iv						
1	Ir	nled	ning1				
	1.1		Bakgrund1				
	1.2		Mål1				
	1.3		Begränsningar1				
	1.4		Metod1				
2	C	USL	JM i kombination med ANN för tillståndsövervakning2				
	2.1		CUSUM				
	2.2		Fallstudie, del 13				
	2.3		Fallstudie, del 26				
3	S	enso	orvalidering genom klassificering10				
	3.1		Bakgrund10				
	3	.1.1	Sensorvalidering - traditionell10				
	3	.1.2	Gasturbinkonfigurationer10				
	3.2		Sensorvalidering – klassificering				
	3.3		Återskapande av förlorade sensorvärden12				
	3.4		Fallstudie12				
	3	.4.1	Datagenerering och träning av klassificeringsnätverk12				
	3	.4.2	Resultat - klassificering14				
	3	.4.3	Resultat – Återskapande av förlorade sensorvärden16				
4 Kalibrerbar ANN modell för tillståndsövervakning		rerbar ANN modell för tillståndsövervakning17					
	4.1 Bakgrund						
	4.2		Fallstudie				
5	S	amr	nanfattning21				
6	R	Referenser					

# Nomenklatur

Н	Antal dolda neuroner
S	Kumulativ summa eller summa
h	Konfidensgränskonstant
k	Slackparameter
n	Undergrupp eller Antal exempel
х	Värde eller parameter
z	Standardiserad avvikelse
δ	Vinkel
σ	Standardavvikelse

#### Index

Н	Hög
i	Nummer
L	Låg

# Förkortningar

ANN	Artificiellt neuronnät
CUSUM	Kumulativ summa
OEM	Originaltillverkare
PCA	Principalkomponentanalys
PLS	Partiella minsta kvadratmetoden (Partial least square)

# 1 Inledning

Avdelningen för Kraftverksteknik vid Lunds Universitet har under en lång tid undersökt möjligheterna med att använda datadrivna metoder, typ artificiella neuronnät, för övervakning i kraftverkssammanhang. Denna rapport är en fortsättning på det arbete och har skett i samarbete med Siemens Industrial Turbomachinery, Göteborgs Energi, Öresundskraft samt Thomas Palmé från Stavangers Universitet.

Rapporten består av tre studier, listade nedan:

- 1. Genom att kombinera ett prestandapredikterande ANN med CUSUM kunna detektera avvikelser i ett tidigare stadium och undvika behovet av omträning av ANN modellen.
- 2. Genom att träna ett ANN som en klassificerare kunna detektera sensorfel på ett tidigt stadium samt återskapa förlorade mätvärden.
- 3. Genom att basera ett prestandapredikterande ANN på simuleringsdata kunna kalibrera in ANN modellen till olika gasturbinindivider och på så sätt undvika behovet av omträning.

# 1.1 Bakgrund

Avregleringen av elmarknaden har medfört nya ekonomiska och miljömässiga krav på kraftverksanläggningar och deras ägarorganisationer. Endast termodynamisk optimering är inte tillräckligt längre för en ekonomisk och miljömässig framgångsrik affärsstrategi. Flertal oberoende studier har visat att det krävs en kombination av bl.a. effektiv anläggningsövervakning och feldiagnostik kombinerat med konditionsbaserat underhåll och ekonomisk optimering av anläggningen i realtid. För att realisera dessa nya krav krävs utveckling av nya, snabba och noggranna modeller samt verktyg som kan kombinera driftsövervakning med optimering av anläggningsdriften. Olika tekniker för övervakning av kraft- eller värmeproducerande anläggningar har utvecklats på senare år och artificiella neurala nätverk (ANN) har visat sig vara ett kraftfullt verktyg för övervakning och konditionsbestämning.

# 1.2 Mål

Det gemensamma huvudmålet med de tre studierna är att i förlängningen uppnå tillståndsbaserat underhåll genom intelligent övervakning.

# 1.3 Begränsningar

Tittar man på helheten så har det inte undersökts hur respektive modell reagerar på andra typer av fel, t.ex. hur sensorvalideringsmodellen reagerar på ett riktigt fel (och tvärtom såklart).

# 1.4 Metod

ANN modellerna har tränats antingen med NeuroSolutions eller Matlab. Modellernas prestanda har verifierats och resultaten analyserats.

## 2 CUSUM i kombination med ANN för tillståndsövervakning

Detta kapitel behandlar en utvärdering där artificiella neurala nätverk kombineras med en sekvensanalysteknik för tillståndsövervakning av gasturbiner. För denna studie har driftdata från en SGT-600 gasturbin använts till träningen av en ANN modell, som sedan använts för prestandaprediktioner. Simulerade avvikelser har påförts två olika uppsättningar driftdata, förvärvade med ett års mellanrum, varpå dessa driftdata jämförs med motsvarande ANN prediktioner. Den kumulativa summan (CUSUM) används därpå för att förbättra och underlätta upptäckten av sådana avvikelser i gasturbinprestanda. Resultaten är lovande och visar en snabb upptäckt av små förändringar samt även potentialen att upptäcka förändringar i prestanda för en degraderad gasturbin.

#### 2.1 **CUSUM**

I den statistiska teorin används ofta styrdiagram för att upptäcka en förändring i medelvärdet för en process. Det huvudsakliga målet med dessa styrdiagram är att skilja naturliga variationer från onaturliga beteende så att man kan vidta snabba och korrekta åtgärder. Det finns flera typer av styrdiagram varav Shewhartdiagram är ett av de vanligare. Andra exempel är "X diagram" som används för styrning centrala tendenser och "R diagram" (eller  $\sigma$  diagram) som används för att styra variabilitet.

Om en variabel är normalfördelad med medelvärdet  $\bar{x}$  och standardavvikelsen  $\sigma$  så är sannolikheten att  $x_i$  faller inom intervallet [ $\bar{x} - 3\sigma$ ,  $\bar{x} + 3\sigma$ ] 0,9973. Om istället en undergrupp av n observationer beaktas kommer det nya intervallet bli [ $\bar{x} - 3\sigma/\sqrt{n}$ ,  $\bar{x} + 3\sigma/\sqrt{n}$ ]. Om en förändring mellan det förväntade och det uppmätta värdet uppstår kan ett Shewhartdiagram ge en bra detektion av detta. Den stora nackdelen med Shewhartdiagram är deras oförmåga att använda informationen i en sekvens. Som ett resultat av det är förändringar mellan det förväntade medelvärdet och det uppmätta medelvärdet svåra att upptäcka om förändringen inträffar innanför konfidensnivån för Shewhartdiagrammet. CUSUM utvecklades för att lösa detta problem och det görs genom att man tittar på en sekvens av mätningar och ackumulerar skillnaden mellan uppmätt och förväntat medelvärde över tid. Det finns flera typer av CUSUM algoritmer och de har alla sitt ursprung i det arbete som föreslogs av Page. Det första steget är att beräkna de standardiserade avvikelserna för observationerna från det eftersträvade processmedelvärdet, som visas i Ekvation 1.

$$z_i = \frac{x_i - \bar{x}}{\sigma_r} \tag{1}$$

Där  $x_i$  är det observerade värdet vid tiden i,  $\bar{x}$  det eftersträvade processmedelvärdet och  $\sigma$  en uppskattning av standardavvikelsen för de observerade värdena. Dessa ackumuleras över tiden för att beräkna den kumulativa summan, S, vid varje tidpunkt i som visas i Ekvation 2.

$$S_i = S_{i-1} + z_i, \, d\ddot{a}r \, S_0 = 0 \tag{2}$$

Om det finns en förskjutning i processmedelvärdet tenderar  $z_i$  att vara större eller mindre än målet och CUSUM kommer antingen stadigt öka eller minska. Beroende på hur stor förändringen är kommer antalet observationer som krävs för detektion att variera. I ett tvåsidigt CUSUM kontrolldiagram används följande samband för detektion av drift, se Ekvation 3.

$$S_{Hi} = \max \left[ 0, (z_i - k) + S_{Hi-1} \right]$$
(3)  
$$S_{Li} = \min \left[ 0, (z_i + k) + S_{Li-1} \right]$$

Parametern k är ett referensvärde eller tillåtet slack i processen. Ett vanligt val av k är 0,5 vilket är lämpligt när en förskjutning i storleksordningen en standardavvikelse i processmedelvärdet önskas upptäckas. Ett CUSUM kontrolldiagram innefattar även nedre och övre larmgränser, eller konfidensintervall, med en magnitud på  $\pm h\sigma$  där h normalt har värdet 4 eller 5. Dessa gränser har används för att skilja mellan slumpmässiga förändringar och bestående förändringar av medelvärdet.

#### 2.2 Fallstudie, del 1

ANN modellen som använts i denna studie är konfigurerad med fyra indataparametrar och sju utdataparametrar och visas i figur 1 nedan.



Figur 1. Modellkonfiguration.

Noggrannheten hos ANN modellen kan illustreras genom att plotta ANN prediktionerna tillsammans med motsvarande driftdata från gasturbinen, vilket kan ses i Figur 2 för motsvarande fem dygns drift.



Figur 2. ANN prediktioner och mätvärden.

För att minimera risken för att stöta på oönskade influenser i studien väljs en mindre sektion data ut, motsvarande 19 timmar, och plottas igen i Figur 3.



Figur 3. ANN prediktioner och mätvärden.

Traditionellt används CUSUM kontrolldiagram för processer där mätdata är normalfördelade runt en konstant medelvärde. I det här fallet representeras det konstanta medelvärdet av ANN prediktionerna och distributionen kommer att beräknas utifrån hur långt över eller under mätvärdena hamnar från dessa prediktioner. För att kontrollera att driftdata är normalfördelat kring sina motsvarande prediktioner beräknas standardavvikelsen enligt Ekvation 4 och illustreras i Figur 4.

$$\sigma = \sqrt{\frac{1}{n-1} \sum_{i=1}^{n} (x_i - \bar{x})^2}$$
(4)

Figur 4. Mätvärdenas fördelning.

Som det verkar är mätningarna normalt (eller nära normalt) fördelade runt motsvarande prediktioner, vilket är en indikation på att ANN modellen är bra tränad. Det betyder också att förutsättningarna för att använda CUSUM kontrolldiagram är gynnsamma eftersom den kumulativa summan kommer att förbli runt noll så länge gasturbinen fungerar tillfredsställande. Som jämförelse plottas ett Shewhart och ett

dubbelsidigt CUSUM kontrolldiagram tillsammans (Figur 5) för den valda perioden. En gruppering på fem mätvärden har använts, d.v.s. ett medelvärde av fem mätningar jämförs med motsvarande medelvärde av fem prediktioner. Övre och undre larmgränser har satts enligt standard praxis.



Figur 5. CUSUM och Shewhartdiagram

Från kontrolldiagrammen kan man dra slutsatsen att båda håller sig runt noll, vilket indikerar att gasturbinen fungerar som förväntat. För att illustrera styrkan av ett CUSUM kontrolldiagram simuleras ett litet effekttapp på 15 kW efter datapunkt 100 varefter motsvarande plotter genereras igen. Figur 6 motsvarar Figur 3 och Figur 7 motsvarar Figur 5.



Figur 6. ANN prediktioner och mätvärden med ett pålagt effekttapp om 15 kW.



Figur 7. CUSUM och Shewhartdiagram ett pålagt effekttapp om 15 kW.

Detektering av ett så litet effekttapp är långt ifrån självklart när man tittar på Figur 6 eller på Shewhartdiagrammet i Figur 7. Däremot blir det ytterst tydligt när man studerar CUSUM diagrammet där effekttappet upptäcks efter motsvarande 1½ timme. Hur snabbt man kan göra en detektering beror dock på flera faktorer, hur man konfigurerar sitt CUSUM diagram med avseende på larmgränser och hur många datapunkter man använder i sin gruppering etcetera.

För tillräckligt stora avvikelser kan ett Shewhartdiagram vara tillräckligt men för en snabb detektion av små avvikelser är ett CUSUM diagram mycket kraftfullt. Begränsningar uppstår dock nästan omedelbart eftersom alla gasturbiner degraderas. En liten permanent förskjutning i gasturbinprestanda kommer snabbt göra att den kumulativa summan avviker från noll. I nästa avsnitt kommer detta att diskuteras och ett exempel visas på hur det kan kringgås.

#### 2.3 Fallstudie, del 2

För att använda CUSUM över längre tid måste metoden, som beskrevs i förra stycket, generaliseras. Istället för att titta på absoluta förändringar i den kumulativa summan föreslås att riktningsförändringarna (derivatan) studeras. Om skillnaden mellan uppmätt och predikterad prestanda är konstant över tid kommer den kumulativa summan representeras av en rak linje. Om ytterligare skillnader uppstår så kommer linjen ändra riktning, d.v.s. derivatan kommer skilja sig från noll, vilket visas i Figur 8.



Figur 8. Generaliserad CUSUM.

Om *j* (i Figur 8) representerar nuvarande tid och *x* tillfället då en ytterligare skillnad (mellan uppmätt och predikterad prestanda) uppstår så är *x-i* antalet punkter som använts för beräkning av första medellinjen samt *j-x* antalet för beräkning av den andra medellinjen. Tidpunkten *x* är okänd och att identifiera denna utan att generera falska larm samtidigt som man upprätthåller en rimlig detektionshastighet är en fråga om att välja *x-i*, *j-x* samt  $\delta_{MAX}$ , där  $\delta_{MAX}$  är den maximalt tillåtna vinkeln mellan medellinjerna. För att utvärdera denna metod används data insamlad ett år efter ANN modellen togs fram. Under detta år har gasturbinen bl.a. genomgått en översyn med byte av brännkammare samt ackumulering av tusentals drifttimmar och flertalet starter. Det förväntade är att prestanda skiljer sig en hel del från tidpunkten då ANN modellen togs fram, vilket också exemplifieras i Figur 9 där både den predikterade och uppmätta eleffekten plottas.



Figur 9. ANN prediktioner mätvärden.

Som framgår av figuren är den uppmätta effekten cirka 500 kW lägre än vad den förväntas vara, vilket tyder på en märkbar degradering. Hursomhelst, om de två plottade linjerna parallellförskjuts så de

överlappar varandra ser man att gasturbinens beteende fortfarande är väl representerat av ANN modellen, vilket visas i Figur 10.



Figur 10. ANN prediktioner mätvärden, parallellförskjutet.

För att testa den föreslagna, generaliserade CUSUM metoden läggs ett effekttapp på 50 kW på vid datapunk 150 (se Figur 11). I detta fall är x känt och vi kan beräkna och plotta de två medellinjerna för att se vilket  $\delta$  som genereras.



Figur 11. Generaliserad CUSUM.

I verkligheten, när x är okänd och *j*-x och x-*i* måste uppskattas, måste viss eftertänksamhet beaktas. Exempelvis, om *j*-x är består av för många punkter kommer detektionen att försenas. Väljs *j*-x däremot till att bestå av för få punkter kommer  $\delta$  variera kraftigt även under normal drift vilket kan generera falsklarm. Tabell 1 visar, för detta utvalda fall, vilket största värde  $\delta$  erhåller, vid olika kombinationer av *j*-x och x-*i* samt med eller utan det pålagda effekttappet om 50 kW (siffror i kursiv stil representerar de fall med pålagt effekttapp). Tabellen ska tolkas så att i de kombinationsfall där två tal är angivna så skulle en detektion vara möjlig eftersom  $\delta$  vid fallet med effekttapp överskrider fallet utan.

j-x →				
x-i ↓	20	30	40	50
50	4.89°	4.62°	4.35°	4.05°
75	5.14°	4.61°	4.06°	3.52°
100	4.38°	3.59°	2.81° 3.01°	2.10° 3.08°
125	1.56° 3.34°	1.52° 3.49°	1.53° 3.63°	1.55° 3.71°
150	1.97° 3.87°	1.94° 3.97°	1.92° 4.02°	1.88° 4.01°

Tabell 1. Värden för  $\delta$  vid olika kombinationer för j-x och x-i

Sammanfattningsvis kan nämnas att den föreslagna metoden för detektion av prestandadegradering skulle vara möjlig om de ingående parametrarna väljs med lite eftertanke. Detta skulle i sin tur innebära att en modell över en gasturbin inte nödvändigtvis behöver kalibreras eller tränas om bara för att gasturbinens prestanda förändras över tiden.

# 3 Sensorvalidering genom klassificering

# 3.1 Bakgrund

Moderna gasturbiner är alla starkt beroende av tillförlitliga och noggranna sensoravläsningar för övervakning och kontroll, något som gör sensorerna till en viktig del av alla gasturbiner. Trasiga eller drivande sensorer kan orsaka icke optimal drift och i värsta fall en nedstängning av gasturbinen med driftsbortfall och eventuella komponentskador som följd. För att undvika detta görs regelbundna kontroller och kalibreringar av sensorerna, något som är väldigt kostamt. Här föreslås en metod för att utvärdera statusen hos sensorerna med målet att minimera underhållsbehovet och risken för falsklarm. Den föreslagna metoden går ut på att artificiella neuronnät tränas för att kunna klassificera sensorfel och återskapa bortfallna sensorvärden. Metoden testas på två typer av gasturbiner, en enaxligt och en tvåaxlig maskin, för att verifiera metodens generaliserbarhet.

#### 3.1.1 Sensorvalidering - traditionell

Sensorvalidering bygger på samband mellan parametrar och tre vanligt förekommande linjära metoder för sensorvalidering är principalkomponentanalys (PCA), partiella minsta kvadratmetoden (PLS) samt Kalmanfilter. Artificiella neuronnät är även det något som utvärderats ett tag för sensorvalidering och då främst med så kallade autoassociativa neuronnät (AANN). I denna studie används inte AANN utan "traditionella" ANN, tränade som klassificerare. Målet med detta tillvägagångssätt är att uppnå tidigare detektion av drivande eller trasiga sensorer samt återskapande av mer exakta ersättningsvärden än vid användande av AANN.

#### 3.1.2 Gasturbinkonfigurationer

Olika typer av gasturbinkonfigurationer (i detta fall enaxliga och tvåaxliga) skiljer sig på flera punkter. I en enaxlig maskin är kompressor, turbin och generator mekaniskt förbundna och arbetar därför på samma varvtal inom hela operationsprofilen. I en tvåaxlig gasturbin är turbinen uppdelad på två, en så kallad gasgenerator som driver kompressorn och en kraftturbin som driver generatorn. P.g.a. sina olikheter så både regleras och beter sig de två typerna på olika sätt, illustrerat i Figur 12.



Figur 12. Driftsprofil för en enaxlig (nedre) respektive tvåaxlig (övre) gasturbin.

#### 3.2 Sensorvalidering – klassificering

I denna studie har klassificeringsnätverket byggts upp så att varje sensor tilldelas två klasser, en för positiv drift och en för negativ drift. Utöver detta tillkommer en klass då alla sensorer fungerar som de ska. Detta exemplifieras i Tabell 2 med två fiktiva sensorer där de två första raderna visar två mättillfällen där båda sensorerna är friska, följt av två mättillfällen med 10 % positiv drift i sensor ett, vidare följt av två mättillfällen med 20 % positiv drift i sensor två, osv.

Sensor 1	Sensor 2	Klass 1:	Klass 2: S <sub>1</sub>	Klass 3: S <sub>2</sub>	Klass 4: S <sub>1</sub>	Klass 5: S <sub>2</sub>
värde	värde	Frisk	för hög	för hög	för låg	för låg
1	2	1	0	0	0	0
5	6	1	0	0	0	0
1.1	2	0	1	0	0	0
5.5	6	0	1	0	0	0
1	2.4	0	0	1	0	0
5	7.2	0	0	1	0	0
0.9	2	0	0	0	1	0
4.5	6	0	0	0	1	0
1	1.6	0	0	0	0	1
5	4.8	0	0	0	0	1

Tabell 2. Exempel på hur ett dataset för ANN träning kan se ut (två första kolumnerna indata och resterande utdata. S = sensor, 1,2 = sensornummer).

Det är motsvarande detta dataset som används vid träningen av ANN modellen. Det innebär att utdata från modellen enbart består av ettor och nollor. Det innebär också att datasetet som används vid träningen snabbt växer i storlek utifrån hur många klasser man har.

Poängen med detta tillvägagångssätt är att lära neuronnätet att dela in indatamönster i olika klasser. Är alla sensorer friska så kommer neuronnätet klassificera indatamönstret som friskt. Om någon sensor däremot driver så kommer neuronnätet identifiera detta och referera indatamönstret till en annan klass, som i sin tur berättar vilken den drivande sensorn är samt åt vilket håll den driver.

## 3.3 Återskapande av förlorade sensorvärden

Efter en drivande sensor blivit identifierad är det av intresse att återskapa det egentliga värdet på parametern som den sensorn representerar. I detta fall har vanliga regressionsnätverk använts där alla resterande (friska) sensorvärden används för att prediktera det förlorade värdet. Det innebär i praktiken att ett ANN tränas för varje parameter/sensor och i respektive fall så används alla övriga parametrar som indata.

#### 3.4 Fallstudie

#### 3.4.1 Datagenerering och träning av klassificeringsnätverk

I denna studie har data för ANN träning tagits fram med gasturbintillverkarens simuleringsprogram, ett program med mycket bra överrensstämmelse mot deras verkliga gasturbiner. Vid dataframtagningen valdes gasturbinernas huvudparametrar ut och simuleringsdata producerades inom ett valt driftsområde. Efter grunddatasetet var framtaget lades antagna sensorfel på datasetet. Vidare introducerades ett vitt brus, representativt med verkligliga brusnivåer. Bruset läggs till som ett sätt att verifiera huruvida metoden hanterar mer realistisk data. Ett klassificeringsnätverk tränades och dess prestanda utvärderades varpå de pålagda sensorfelen justerades och ett nytt nätverk tränades. Iterativt hittades ett optima och de lägsta detekterbara driftnivåerna identifierades. Det två neuronnäten syns i Figur 13.



Figur 13. Modellstrukturer.

Grunddataseten är framtagna genom att variera lasten mellan 10 % och 100 % (i steg om 5 procentenheter) samt atmosfärstemperaturen mellan -25 °C och 25 °C (i steg om 5 °C) samtidigt som atmosfärstryck och relativ fuktighet hölls konstanta vid ISO standard (1,013 bar respektive 60 %). Parameterintervallen, för respektive gasturbintyp, syns i Tabell 3.

х	SGT-600	SGT-800	Enhet
$P_{gen}$	2.20 - 27.8	4.40 - 53.5	MW
t <sub>amb</sub>	± 25	± 25	°C
٦c	41.3 - 88.2	-	kg/s
$\Delta p_{\text{bell}}$	-	0.0023 - 0.0061	bar
IGV	-	-40 - 1.2	0
t <sub>3</sub>	182.9 – 394.0	317.8 – 451.8	°C
p <sub>3</sub>	5.90 – 15.8	10.7 – 22.2	bar
Pf	0.4 - 1.8	0.9 – 3.0	kg/s
t <sub>7</sub>	273.9 – 553.0	366.3 - 604.7	°C
p <sub>7</sub>	1.013 – 1.022	1.065 – 1.152	bar

Tabell 3. Parameterintervall.

Antalet datamönster hölls nere med en ganska grov parametervariation (5 procentenheter respektive 5 °C) eftersom det slutliga datasetet, som senare används till träningen, växer avsevärt för varje sensorfel man lägger på. Ett verifieringsdataset togs fram, för att kunna kontrollera nätverkets prestanda efter träningen, genom att variera lasten mellan 12,5 % och 97,5 % samt temperaturen mellan -22,5 °C och 22,5 °C. Tränings- och testdatamönster kan visualiseras genom att plotta dem i en 3D rymd, i Figur 14 visas avgastemperaturen från den enaxliga maskinen (modell SGT-800).



Figur 14. Exempel på tränings- och testdata.

Brusnivåerna som är pålagda dataseten genererades med en slumpgenerator vilket resulterar i att avvikelserna är normalfördelade. Nivåerna syns i Tabell 4.

х	$\tau_x$ (vid fullast)	τ <sub>x, SGT-600</sub>	τ <sub>x, SGT-800</sub>
$P_{gen}$	± 0.2 MW	± 0.72 %	± 0.37 %
t <sub>amb</sub>	± 0.1 °C	± 0.40 %	± 0.40 %
Sc	± 0.08 kg/s	± 0.09 %	-
$\Delta p_{\text{bell}}$	± 0.00015 bar	-	± 2.47 %
IGV	± 0.2 °	-	± 0.20 %
t <sub>3</sub>	± 0.1 °C	± 0.03 %	± 0.02 %
p <sub>3</sub>	± 0.02 bar	± 0.13 %	± 0.09 %
? <sub>f</sub>	± 0.02 kg/s	± 1.11 %	± 0.66 %
t <sub>7</sub>	± 2 °C	± 0.36 %	± 0.33 %
<b>p</b> 7	± 0.001 bar	± 0.10 %	± 0.09 %

#### Tabell 4. Brusnivåer.

#### 3.4.2 Resultat - klassificering

Som nämndes tidigare är det en iterativ process att hitta de minsta möjliga detekterbara driftnivåerna. Utöver det krävs nästan alltid en parametervariation, där t.ex. antalet dolda neuroner varieras, för att hitta ett optimalt nätverk. Tabell 5 visar resultaten efter alla variationer och iterationer är klara.

Klass	SGT-600	) u. brus	SGT600	m. brus	Klass	SGT-800	) u. brus	SGT800	m. brus
1 (H)	-	-	-	-	1 (H)	-	-	-	-
2 (P <sub>gen</sub> )	0.9 %	max	2.0 %	max	2 ( <sub>Pgen</sub> )	0.9 %	max	2.5 %	max
3 (t <sub>amb</sub> )	0.8 %	max	1.3 %	max	3 (t <sub>amb</sub> )	1.0 %	max	2.0 %	max
4 (⊵ <sub>c</sub> )	0.4 %	max	0.5 %	max	4 (∆p <sub>bell</sub> )	0.5 %	max	6.0 %	max
5 (t <sub>3</sub> )	0.5 %	max	0.7 %	max	5 (IGV)	0.5 %	max	0.7 %	max
6 (p₃)	0.3 %	max	0.7 %	max	6 (t <sub>3</sub> )	0.3 %	max	0.4 %	max
7 (₽ <sub>f</sub> )	0.5 %	max	2.5 %	max	7 (p <sub>3</sub> )	0.4 %	max	0.6 %	max
8 (t <sub>7</sub> )	0.5 %	max	1.0 %	max	8 (⊵ <sub>f</sub> )	0.5 %	max	1.7 %	max
9 (p <sub>7</sub> )	0.1 %	max	0.2 %	max	9 (t <sub>7</sub> )	0.5 %	max	1.0 %	max
10 (P <sub>gen</sub> )	-0.9 %	-15 %	-2.0 %	-32 %	10 (p <sub>7</sub> )	0.1 %	max	0.2 %	max
11 (t <sub>amb</sub> )	-0.8 %	-13 %	-1.3 %	-15 %	11 (P <sub>gen</sub> )	-0.9 %	-14 %	-2.5 %	-25 %
12 (ව <sub>c</sub> )	-0.4 %	-10 %	-0.5 %	-13 %	12 (t <sub>amb</sub> )	-1.0 %	-12 %	-2.0 %	-14 %
13 (t₃)	-0.5 %	-13 %	-0.7 %	-25 %	$13(\Delta p_{bell})$	-0.5 %	-18 %	-6.0 %	-38 %
14 (p3)	-0.3 %	-8 %	-0.7 %	-35 %	14 (IGV)	-0.5 %	-10 %	-0.7 %	-25 %
15 (⊡f)	-0.5 %	-8 %	-2.5 %	min	15 (t <sub>3</sub> )	-0.3 %	-13 %	-0.4 %	-25 %
16 (t7)	-0.5 %	-8 %	-1.0 %	-16 %	16 (p₃)	-0.4 %	-9 %	-0.6 %	-34 %
17 (p7)	-0.1 %	min	-0.2 %	min	17 (⊵ <sub>f</sub> )	-0.5 %	-11 %	-1.7 %	-35 %
-	-	-	-	-	18 (t <sub>7</sub> )	-0.5 %	-8 %	-1.0 %	-13 %
-	-	-	-	-	19 (p <sub>7</sub> )	-0.1 %	min	-0.2 %	min

Tabell 5. Intervall inom vilka drift kan upptäckas av olika ANN modeller för de två gasturbintyperna.

Vad tabellen visar är vid vilken driftnivå (i procent) som respektive sensor för respektive gasturbintyp med eller utan brus kan detekteras. Som exempel kan klass 6 (positiv drift för kompressorutloppstryckssensorn) klassificeras mellan 0,7 % upp till maximalt möjligt tryck av SGT-600 modellen tränad med data inklusive brus. 0,7 % motsvarar 0,11 bar vid fullast och 0,04 bar vid lägsta last. Det går också att visualisera klasserna i en 3D rymd, t.ex. visas positiv och negativ driftklass för avgastemperatursensorn för SGT-600 i Figur 15. Den tunna ytan mellan klasserna är där sensorn "kan röra sig fritt" utan att bli klassad som drivande.



Figur 15. 3D representation av två klasser.

#### 3.4.3 Resultat – Återskapande av förlorade sensorvärden

När en sensor har identifierats som drivande med klassificeringsnätverket kan det förlorade sensorvärdet återskapas genom att använda de återstående, friska givarna. För varje parameter/sensor har ett regressionsnätverk tränats att genom använda de resterande friska parametrarna som indata prediktera det förlorade värdet. Detta kan göras med mycket hög noggrannhet (se Tabell 6.), t.o.m. inom brusnivåerna, vilket innebär att de återskapade värdena är minst lika bra som verkliga signaler från sensorerna.

х	SGT-600	SGT-800	
$P_{gen}$	0.03 %	0.23 %	
t <sub>amb</sub>	0.24 %	0.33 %	
<u>ج</u>	0.07 %	-	
$\Delta p_{\text{bell}}$	-	0.39 %	
IGV	-	0.11 %	
t <sub>3</sub>	0.08 %	0.08 %	
p <sub>3</sub>	0.07 %	0.07 %	
Pf	0.35 %	0.23 %	
t <sub>7</sub>	0.10 %	0.23 %	
p <sub>7</sub>	0.02 %	0.03 %	

Tabell 6. Medelfel vid återskapande av förlorade mätvärden.

# 4 Kalibrerbar ANN modell för tillståndsövervakning

# 4.1 Bakgrund

Datadrivna metoders krav på träning inom hela driftområdet kan vara ett problem, speciellt för exempelvis gasturbiner där processen beror starkt av bl.a. omgivningens temperatur, vilket därför kräver mätdata från en lång period för att kunna genomföra träningen. Det kan dessutom vara praktiskt ogenomförbart att få fram mätserier för alla tänkbara fall och det är därför attraktivt att kunna använda teoretiskt simulerade data för att ta bort behovet av att använda verklig processdata vid simuleringar. Teoretiska mätdata möjliggör även att ANN modellerna kan levereras och tas i drift för övervakning vid leveransen av nya gasturbiner.

Den teoretiskt baserade ANN modellen kommer att beskriva en nominell gasturbins beteende. Beteendet hos enskilda individer avviker dock något från det ideala på grund av tillverkningstoleranser. Även om dessa avvikelser är små, påverkar de möjligheten att på ett tidigt stadium detektera avvikelser från normal drift. Inom föreliggande arbete avses därför att utveckla en metod för kalibrering av den teoretiska ANN modellen mot aktuell gasturbinindivid.

Modellkalibreringen måste, vid behov, utföras för varje gasturbinindivid men själva dataframtagningen och träningen av ANN modellen behöver bara göras en gång per gasturbinmodell. Efter ANN modellen är tränad och kalibrerad för att matcha en specifik gasturbinindivid kan den prediktera prestanda för denna inom det intervall den är tränad för. Prediktionerna från ANN modellen används sedan för att i realtid jämföras med motsvarande uppmätta parametrar och på så vis övervaka gasturbinens tillstånd och detektera eventuella fel.

# 4.2 Fallstudie

Parameterstrukturen (in- och utdata till modellen) fastställdes i samråd med Siemens och simuleringsdata producerades med Siemens inhouse program för prestanda beräkningar av gasturbiner, GT-24 (GT Perform). Data togs fram för varierande driftsförhållande (d.v.s. varierande atmosfärstillstånd) i intervall som matchar verkligheten. Detta innebär att för varje indataparameter till ANN modellen så bestäms ett intervall och en upplösning var på data genereras för alla möjliga kombinationer. Kalibreringsparametrarna, som också är indataparametrar till ANN modellen, är fyra till antalet, två för kompressorn och två för turbinen. Med hjälp av dessa parametrar kan gasturbinens tillstånd beskrivas och genom att justera dessa kan ANN modellen matchas till olika gasturbinindivider. Hela strukturen för ANN modellen syns i Figur 15. Exempel på den tränade ANN modellens noggrannhet kan ses i Figur 16 och 17.







Figur 17. ANN prediktioner av eleffekten



Figur 18. ANN prediktioner av turbinutloppstemperaturen.

Den tränade och verifierade ANN modellen ska sedan kalibreras mot verkliga gasturbiner. I detta fall har data från fyra SGT-800 maskiner erhållits, varav tre står på Rya verket i Göteborg och en på Västhamnsverket i Helsingborg. Innan det kan ske verifieras kalibreringsmetodiken (som ses i Figur 18) genom att ANN modellen kalibreras mot simulerade driftfall. Det vill säga att en uppsättning värden på kalibreringsparametrarna väljs varpå ANN modellen predikterar prestandan, vårt simulerade driftfall. Sen används ANN modellen (nollställd) tillsammans med kalibreringsalgoritmen och det simulerade driftfallet för att hitta värdena på kalibreringsparametrarna.



Figur 19. Kalibreringsmetodik [A.M.Y. Razak, Industrial Gas Turbines: Performance and Operability]

## 4.3 Resultat av fallstudien

Att ställa in ANN modellen till simulerade driftfall fungerade bra men inga vidare resultat uppnåddes när detsamma försöktes med riktig driftdata från verkliga maskiner. Det gick inte att producera några resultatfiler eller jämförelser från denna fallstudie eftersom det inte gick att kalibrera in ANN modellen till verklig data. Anledningen till att det inte gick att simulera driftsfallen tros vara att den simuleringsdata som användes inte var tillräcklig då bland annat gasturbinens regleralgoritm inte fanns med som indata till ANN modellen. Regleralgoritmen finns förvisso inbakad i Siemens simuleringsprogram men att ta fram korrekt data som innefattar regleralgoritmen är mycket tidskrävande. Ytterligare en parameter som utelämnades under testet då dess variation ansågs liten var förhållandet mellan kol och väte i bränslet. Denna parameter bör även tas med vid framtida tester då denna kommer att variera mellan de olika maskinerna som körs.

Tyvärr har inte någon vidare analys i denna fas kunnat utföras då arbetet med att ta fram och bearbeta träningsdata med simuleringsprogrammet GT Perform underskattades. Detta medförde att tidsramen för projekten blev hårt pressad och simuleringsdata blev tillgänglig alldeles för sent i projektet. Detta har medfört att det inte har kunnat utföras någon analys av själva problemställningen kring de teoretiska simuleringsdata. Detta får därför ses som framtida arbete då metodiken som helhet bör fungera.

# 5 Sammanfattning

#### Kalibrerbara ANN modeller för tillståndsövervakning

Genom att använda Siemens "performance deck" (GT-24) för framtagning av simuleringsdata kan kalibrerbara ANN modeller utvecklas. Tanken med kalibrerbara ANN modeller är att enbart en modell, för t.ex. tillståndsövervakning, ska tas fram för respektive gasturbinmodell och sedan kalibreras till olika individer. Detta görs genom att inkludera ett antal kalibreringsparametrar, bl.a. verkningsgrader och vidhet, i dataframtagningen. Dessa parametrar kan sedan använda för att finjustera ANN modellen för att matcha specifika individer. Denna finjustering kan behövas dels p.g.a. små skillnader från produktionen men även senare i driften då komponenter byts ut eller gasturbinen degraderas.

#### ANN och CUSUM för tillståndövervakning

Flera fördelar kommer med att applicera CUSUM för driftavvikelsedetektion i kombination med en prestandamodell. Mycket små driftavvikelser kan detekteras snabbt samtidigt som man kan undvika krävande omträningsprocesser för prestandamodellen i takt med att gasturbinen t.ex. degraderas. CUSUM står för kumulativ summa och är en teknik som traditionellt används för att övervaka produktionsprocesser genom att ackumulera skillnader mellan ett förväntat medel och uppmätta värden. För att applicera metoden för tillståndsövervakning så används skillnaderna mellan predikterad prestanda och uppmätt prestanda.

#### Sensorvalidering genom klassificering

Genom korrekt träning av en sensorvalideringsmodell kan detektion av drivande sensorer göras på en tidig nivå samtidigt som syntetiska ersättningsvärden produceras. Här utvärderas en metod där ANN används som klassificerare för att upptäcka sensorfel med lovande resultat.

## **6** Referenser

SGC Rapport 171, Modellering av hybridanläggning samt utveckling av övervakningssystem för Västhamnsverket baserat på Artificiella Neurala Nätverk, Magnus Fast & Mohsen Assadi, Institutionen för Energivetenskaper, Lunds Universitet, 2008

SGC Rapport 183, Tillståndsövervakning och termoekonomisk driftoptimering av en hybridanläggning med artificiella neurala nätverk, Magnus Fast & Mohsen Assadi, Institutionen för Energivetenskaper, Lunds Universitet, 2008

Magnus Fast et al., Condition based maintenance of gas turbines using simulation data and artificial neural network, a demonstration of feasibility, ASME Turboexpo, 2008

Magnus Fast et al., Application of Artificial Neural Network to the Condition Monitoring and Diagnosis of a CHP plant, ECOS, 2008

Magnus Fast et al., Development and multi-utility of an ANN model for an industrial gas turbine, Applied Energy, 2009

Magnus Fast et al., A novel approach for gas turbine condition monitoring combining CUSUM technique and artificial neural network, ASME Turboexpo, 2009

Thomas Palmé et al., Different Condition Monitoring Models for Gas Turbines by means of Artificial Neural Networks, ASME Turboexpo, 2009

Magnus Fast et al., Gas Turbine Sensor Validation through Classification with Artificial Neural Networks, ECOS, 2009



Scheelegatan 3, 212 28 Malmö • Tel 040-680 07 60 • Fax 040-680 07 69 www.sgc.se • info@sgc.se