


MASKININLÄRNING, ELKVALITET OCH SMARTA ELNÄT

RAPPORT 2020:691



Maskininlärning, elkvalitet och smarta elnät

Tillämpning av maskininlärning vid analys av elnät

EBRAHIM BALOUJI

ERIK BERGGREN

KARL BÄCKSTRÖM

ISAC KÄRRMAN

JOHAN RÅDEMAR

ISBN 978-91-7673-691-3 | © Energiforsk september 2020

Energiforsk AB | Telefon: 08-677 25 30 | E-post: kontakt@energiforsk.se | www.energiforsk.se

Förord

Projektet *Maskinlärning i olika distributionsnät* har applicerat state of art machine learning metoder för att bättre förstå och överblicka våra elnät. I samband med att elnäten förändras med fler uppkopplade enheter och nya typer av laster, kommer fler utmaningar. Nya digitala lösningar krävs för att säkerställa god elkvalitet. Idag finns mycket elkvalitetsdata insamlad men effektiv analys av denna saknas. I ett första steg tillämpades en unik metod för klassificering och orsaksidentifiering av elkvalitet. I ett andra steg utfördes en behovsanalys av ytterligare funktioner ska kunna möjliggöras för maskininlärning.

Johan Rådemar på Eneryield har varit projektledare för projektet.

Energiforsk vill framföra ett stort tack till referensgruppen, som bidragit med synpunkter, erfarenheter och varit ett bollplank för Johan under projektets gång. Referensgruppen har bestått av:

- Ferruccio Vuinovich (Göteborg Energi)
- Ilijaz Kenjar (Göteborg Energi)
- Susanne Ernfridsson (Härryda Energi)
- Pontus Claesson (Härryda Energi)
- Hampus Halvarsson (Jämtkraft)
- Anton Grönkvist (E.ON)
- Michele Luvisotto (ABB)
- Subrat Sahoo (ABB)
- Arne Berlin (Vattenfall Eldistribution)
- Magnus Brodin (Skellefteå Kraft)
- Peter Ols (Tekniska Verken)

Programmet Elnätens digitalisering och IT-säkerhets programstyrelse, som initierat, följt upp och godkänt projektet, består av följande ledamöter:

- Kristina Nilsson, Ellevio ordförande
- Arne Berlin, Vattenfall Eldistribution
- Svante Nygren, Svenska kraftnät
- Patrik Björnström, Sveriges Ingenjörer (Miljöfonden)
- Ferruccio Vuinovich, Göteborg Energi
- Teddy Hjelm, Gävle Energi (Elinorr)
- Torbjörn Solver, Mälarenergi vice ordförande
- Magnus Sjunnesson, Öresundskraft
- Peter Ols, Tekniska Verken i Linköping
- Adam Nilsson, Jämtkraft
- Magnus Brodin, Skellefteå Kraft
- Johan Örnberg, Umeå Energi Elnät
- Peter Addicksson, HEM

- Jesper Bjärvall, Karlskoga Energi
- Malin Wallenberg, VB Energi
- Claes Wedén, ABB Power Grids Sweden
- Katarina Porath, ABB
- Björn Ållebrand, Trafikverket
- Anders Fredriksson, Energiföretagen Sverige

Följande bolag har deltagit som intressenter till projektet. Energiforsk framför ett stort tack till samtliga bolag för värdefulla insatser.

Ellevio, Vattenfall Eldistribution, Göteborg Energi, Mälarenergi Elnät, Öresundskraft Elnät, Tekniska Verken i Linköping, Skellefteå Kraft Elnät, Umeå Energi Elnät, Jämtkraft Elnät, Eskilstuna Strängnäs Energi & Miljö, Karlstads El- och Stadsnät, Borås Elnät, Halmstad Energi och Miljö Nät, Luleå Energi Elnät, Borlänge Energi, Nacka Energi, Västerbergslagens Elnät, PiteEnergi, Södra Hallands Kraftförening, Karlskoga Elnät, Svenska kraftnät, Sveriges ingenjörer (Miljöfonden), Trafikverket, Forumet Swedish Smartgrid, Teknikföretagen, Huawei Sverige, Exeri, Evado, ABB Power Grids Sweden, ABB, Elinorr ekonomisk förening; Bergs Tingslags Elektriska, Blåsjön Nät, Dala Energi Elnät, Elektra Nät, Gävle Energi, Hamra Besparingsskog, Hofors Elverk, Härjeåns Nät, Härnösand Elnät, Ljusdal Elnät, Malungs Elnät, Sandviken Energi Nät, Sundsvall Elnät, Söderhamn Elnät, Åsele Elnät, Årsunda Kraft & Belysningsförening och Övik Energi Nät.

Stockholm i augusti 2020

Susanne Stjernfeldt
Energiforsk AB
Programområde Elnät, Vindkraft och Solel

Här redovisas resultat och slutsatser från ett projekt inom ett forskningsprogram som drivs av Energiforsk. Det är rapportförfattaren/-författarna som ansvarar för innehållet.

Sammanfattning

I samband med att samhället elektrifieras i högre grad och elnätet förändras genom nya distribuerade kraftkällor och olika typer av laster, uppkommer nya utmaningar. En viktig komponent som behöver tas hänsyn till är elkvalitet (Power Quality, PQ), som i dagsläget övervakas av nätägare genom mätning och analys. Genom framväxten av artificiell intelligens kan fördjupad analys av den PQ-data som samlas in göras, vilket skapar nya möjligheter att åtgärda PQ-störningar. Eneryield är en startup i Göteborg som, baserat på sju års forskning, utvecklat nya maskininlärningsbaserade metoder för att analysera PQ-störningar.

Syftet med projektet är att använda Eneryields metoder för att klassificera och identifiera grundorsak och riktning för elkvalitetsstörningar. Vidare ämnar projektet identifiera utmaningar och behov för nätägare, och utreda hur datadrivna metoder på bästa sätt kan bistå framtida arbete. Målet är att ta fram ett förslag på hur en maskininlärningsbaserad PQ-analys kan tillgängliggöras, förslagsvis i en ny typ av utvidgad och mer djupgående analysrapport.

Eneryield ledde projektet tillsammans med Göteborg Energi, Härryda Energi, E.ON., Jämtkraft, Vattenfall, ABB och Tekniska Verken. Nätägare bidrog med PQ-data från de mätare de har utplacerade på sina elnät. En behovsanalys genomfördes som indikerade att klassificering och identifiering av grundorsak och mer precis identifiering av riktning för spänningsdippar och transienter är av stort intresse. Eneryield genomförde därför en maskininlärningsbaserad analys för detta och lyckades nå resultat med en träffsäkerhet på upp till 99 procent för klassificering, 95 procent för grundorsaksidentifiering och 80 procent för riktningsidentifiering.

Slutsatsen är att Eneryields maskininlärningsmetoder är möjliga att använda på data från nätägare med hög träffsäkerhet. Utmaningar uppkom då data exporterades från nätägarens databas och var även relaterad till datans kvalitet. De nya analysmetoderna har stora möjligheter att bidra till framväxten av ett smartare elnät.

Summary

In connection with society being electrified to a greater degree and the power grid changing with new distributed power sources and different types of loads, new challenges arise. An important component that needs to be taken into account is power quality (PQ), which is currently monitored and maintained by grid operators through measurement and analysis. Through the emergence of artificial intelligence, in-depth analysis of the PQ-data collected can be done, which creates new opportunities to address PQ-disturbances. Eneryield is a startup in Gothenburg that, based on seven years of research, has developed new machine learning-based methods for analyzing PQ-disturbances.

The purpose of the project is to use Eneryield's methods to classify and identify the root cause and direction of PQ-disturbances. Furthermore, the project aims to identify challenges and needs for grid operators, and investigate how data-driven methods can best assist their future work. The aim is to produce a proposal on how a machine learning-based power quality analysis can be made accessible in a new type of expanded and in depth analysis report.

Eneryield led the project together with Göteborg Energi, Härnäs Energi, E.ON., Jämskraft, Vattenfall, ABB and Tekniska Verken. The grid operators contributed with PQ-data from the meters they have placed on their power grids. A needs analysis was carried out, which gave indications that classification and identification of the root cause and a more precise analysis for direction of voltage dips and transients is of great interest. Eneryield therefore carried out a machine learning based analysis for this and succeeded in achieving results with an accuracy of up to 99 percent for classification, 95 percent for root cause identification and 80 percent for direction identification.

The conclusion is that Eneryield's machine learning-based methods are possible to use on data from grid operators with high accuracy. However, challenges arose when data was exported from grid operators' databases and were also related to the quality of the data. The new analysis methods have great potential to contribute to a smarter electricity grid.

Innehåll

1	Inledning	9
1.1	Bakgrund	9
1.1.1	Syfte och mål	10
1.2	Struktur	10
2	Artificiell intelligens	11
2.1	Maskininläring	11
2.2	Djupinläring (DL)	12
3	Elkvalitet (PQ)	13
3.1	Definition av PQ	13
3.2	Olika typer av PQ-störningar	13
3.2.1	Händelser	13
3.2.2	Variationer	14
3.3	Konsekvenser av PQ-störningar	15
4	Nuvarande arbetsmetoder	17
4.1	Mätning	17
4.2	Datahantering	18
4.3	Analys	18
5	Behovsanalys	19
5.1	Utmaningar relaterade till elkvalitet	19
5.2	Värdet av att förstå PQ-störningars grundorsak	20
6	Analys och resultat	21
6.1	Datahantering	21
6.1.1	Insamling av data	21
6.1.2	Förbehandling	23
6.2	Analys med ML-baserade metoder	23
6.2.1	Klassificering av PQ-störningar	24
6.2.2	Identifiering av PQ-störningars riktning	25
6.2.3	Grundorsaksidentifiering	28
6.2.4	Förutse energikonsumtion	32
7	Tillgängliggörande av resultat	35
7.1	Minimum Viable Product: PQ-rapport	35
7.2	Implementering i nuvarande system och IT-säkerhet	36
8	Reflektion	38
8.1	Utmaningar - insikter från projektet	38
8.1.1	Export av data	38
8.1.2	Datans kvalitet	39
8.2	Möjligheter och framtidens smarta elnät	39
8.2.1	Kommunikation, beräkningskraft och datahantering	39

8.2.2	Mätning och analys av en högre samplingsfrekvens	40
8.2.3	Analys "on-the-edge"	40
9	Slutsatser	43
10	Fortsatt arbete	44
11	Referenser	45
Bilaga A: Exemplifiering av analys		47
Bilaga B: PQ-rapport		49

1 Inledning

Här ges en bakgrund, där projektets relevans tydliggörs, när elnätets digitalisering och samhällets pågående elektrifiering belyses. Nya innovativa AI-lösningar tros vara en nyckel för att möjliggöra en sådan omställning. Projektets övergripande ambition är således att utforska nyttan med nya datadrivna metoder, vilket specificeras i *syfte och mål* senare i kapitlet.

1.1 BAKGRUND

I samband med utbyggnad av nya, distribuerade kraftkällor, samt fler uppkopplade enheter förändras elnätet radikalt [1] [2]. I och med samhällets elektrifiering, uppstår nya stora utmaningar för elnätet. Med ett ökat energi- och effektbehov och ett allt mer belastat elnät får störningar också större konsekvenser. Nya intermittenta kraftkällor och sofistikerad teknik ger både upphov till störningar och är känsliga för dessa. Vidare behöver elnätet bli mer flexibelt, parallellt med en försäkran om hög leveranssäkerhet (ibid). I och med detta förväntas elkvalitet (Power Quality, PQ) bli ett allt viktigare fenomen att ta hänsyn till. Därmed ökar behovet för nya tekniska lösningar som kan tillhandahålla en fördjupad insyn av elsystems faktiska hälsa från ett PQ-perspektiv.

Digitalisering av elnät är en nyckel för framtidens elektrifierade samhälle, och idag bedrivs mycket forskning kring de möjligheter som digitaliseringen för med sig för att minska sektorns klimatpåverkan. Digitaliseringen av sektorn syftar till att identifiera nya tekniska möjligheter för att mäta, analysera, planera och styra elnätet på ett mer optimerat sätt. Nya innovativa AI-lösningar kan fungera som en katalysator för den här utvecklingen och möjliggörs i större omfattning då allt mer data samlas in.

Idag sker mätning av PQ på olika platser i nätet, och det finns mycket elkvalitetsdata insamlad, men en mer omfattande och automatiserad analys av sådan data saknas. Här kan datadrivna metoder göra skillnad, men att kombinera maskininläring (Machine Learning, ML), elkvalitet och elektriska system är fortfarande ett relativt utforskat arbetsområde. I det här projektet hoppas projektutföraren sprida kunskap kring ämnet i fråga. Således ämnar projektet vidare studera den nytta som datadrivna metoder kan bidra med. Mer specifikt handlar det om att utforska hur applicering av ML-metoder kan bidra till att upprätthålla, men också öka kvaliteten på och därmed leveranssäkerheten av elektricitet i elnätet.

Det här projektet har utförts under Energiforsks program *Elnätets digitalisering och IT-säkerhet*. Projektet har letts av Eneryield AB, som är specialiserade inom ML, signalbehandling och PQ, i nära samarbete med ett flertal svenska nätägare som har varit vänliga nog att dela med sig av sin kunskap och nödvändig data. Eneryields metoder är förankrade i flera års forskning utförd av två av företagets grundare, Ebrahim Balouji och Karl Bäckström [3] [4] [5], vilka tillsammans utvecklat metoder för effektiv ML-baserad analys av PQ.

1.1.1 Syfte och mål

Syftet med projektet är att utföra en automatiserad klassificering och grundorsaksidentifiering av PQ-händelser, för att förstå underliggande orsaker till störningar. Vidare ämnar projektet identifiera utmaningar och behov för nätägare, och utreda hur datadrivna metoder på bästa sätt kan bistå framtida arbete.

Projektet har två mål:

- Ta fram ett proof-of-concept för klassificering och grundorsaksidentifiering av PQ-händelser utförd på verklig data från nätägare.
- Verifiera marknadsnyttan i samråd med svenska nätoperatörer gällande potentiella applikationer som möjliggörs med hjälp av datadrivna metoder.

1.2 STRUKTUR

Rapporten börjar med att övergripande förklara området Artificiell Intelligens (AI) och PQ. Här tillhandahålls på en övergripande nivå kännedom om delområdena ML och djupinlärning (Deep Learning, DL), respektive olika typer av PQ-störningar samt varför dessa är problematiska. Vidare belyser rapporten på en generell nivå hur nätägare idag jobbar med PQ, och då i relation till mätning, datainsamling och analys.


I kapitel fem presenteras den behovsanalys som gjordes under projektet. Kapitel sex beskriver de ML-analyser som utförts. En övergripande metod samt uppnådda resultat presenteras. I efterföljande kapitel introduceras en MVP, i form av en PQ-rapport, i vilken projektets resultat kan tillgängliggöras. Samma kapitel fortsätter med en diskussion om framtida möjligheter till implementering och IT-säkerhet.

Kapitel åtta är en reflektionsdel som inleder med en diskussion om utmaningar som uppstått under projektet, för att sedan mynna ut i ett resonemang om vilka möjligheter som också finns framöver, både med dagens teknik, samt möjliga framtida uppgraderingar. Rapporten avslutas med slutsats och rekommendationer för fortsatt arbete.

2 Artificiell intelligens

För en ökad förståelse gällande de olika begrepp som används genomgående i rapporten, följer en enklare introduktion till några av de datavetenskapliga begrepp som använts i projektet, med fokus på ML och DL.

AI är ett område inom datavetenskapen, vilket enklast kan beskrivas som konstgjord intelligens i form av datorsystem som försöker efterlikna den mänskliga hjärnan [6]. Definitionen av AI förändras kontinuerligt i och med utvecklingen, och dess ämnesområden blir därmed också svåra att avgränsa. Kursen Elements of AI (2020) erbjuder på en hög nivå en bra överblick hur de olika termerna hänger ihop, och hur ett område är delområde inom ett annat, vilket illustreras i *figur 1* [7].



Figur 1: Taxonomin över datavetenskap (1), artificiell intelligens (2), maskininläring (3), djupinläring (4) och data science (5)

2.1 MASKININLÄRNING

ML är en underkategori till paraplybegreppet AI, och i Elements of AI (2020) definieras ML som *“system som blir bättre på en given uppgift när mängden erfarenhet och data ökar”* [7]. ML-algoritmer har alltså förmågan att känna igen och lära sig olika mönster, och utifrån dessa kan de sedan göra egna uppskattningar. Alltså, datorer kan bli självlärande, och utvecklas på egen hand, utan att på förhand vara programmerade specifikt för detta. Begreppet blir snabbt ganska brett, men något förenklat kan man säga att ML är den del av AI, där man tillåter system att bli intelligenta, och därmed kontinuerligt lära utifrån ny data [8].

ML kan tillämpas för att automatiskt finna egenskaper (kännetecken) i data, användbara för klassidentifiering. Inlärningsprocessen kan med fördel utföras genom att tilldela klassificeraren data annoterad med korrekt klass, ofta baserad på egen erfarenhet och detta kallas således vägled inläring (supervised learning). I brist på annoterad data kan inläring istället ske genom algoritmer för icke-

vägled inläring (unsupervised learning), där tilldelad data ej på förhand behöver givet korrekt klass. Ett exempel är *k-means* klustering, en stokastisk algoritm där olika datapunkter separeras baserat på deras euklidiska avstånd, givet antal kluster [9]. Utöver dessa finns även förstärkningsinläring, där inläring sker genom *försök och misstag*. Användning av förstärkningsinläring kräver således inte nödvändigtvis annoterad data, utan endast en väldefinierad belöningsfunktion som förser inlärningsprocessen med en signal som indikerar vilka handlingar som var lyckade, och till vilken grad [8].

2.2 DJUPINLÄRNING (DL)

DL är ett område inom ML, vars metoder baseras på Artificiella neuronnät (Artificial neural network, ANN). ANN är beräkningsstrukturer inspirerade av den biologiska hjärnan. Bestående av många enkla icke-linjära beräkningsenheter, *neuroner*, som kan kopplas samman enligt olika arkitekturer, ofta sorterade i ett antal lager, som definierar *djupet*, genom vilka indatan passerar för beräkning. ANN har under de senaste åren påvisat stor kapacitet för automatisk upptäckt och identifiering av kännetecken användbara för flera problem populära inom ML, exempelvis klassificering. DL har visat sig vara mycket effektivt när det gäller komplexa problem och stora datamängder, men kräver i regel mycket data i inlärningsprocessen [8]. DL har fått stor uppmärksamhet i takt med att beräkningskapaciteten ökat i exempelvis processorer (CPU) och grafikkort (GPU), samt tillgången till stora mängder data.

För att belysa komplexiteten ytterligare, så finns det olika klasser av ANN. Exempelvis finns cykliskt neuronnät (*Recurrent neural network (RNN)*), vilket tillåter indata av variabel dimension, och är flitigt tillämpat inom tidsserieprediktering. Denna typ av ANN kan till exempelvis vara passande för att identifiera, modellera och prediktera tillfälliga dynamiska beteenden. Det finns flera olika typer av RNN, exempelvis Long-short-term-memory (LSTM) som är extra användbart för tidsseriedata med långa tidsberoenden. LSTM hänvisas till i kapitel 6 *Analys och resultat*, där den här typen av terminologi används. Vidare finns faltningsnätverk (*Convolutional neural networks (CNN)*) utrustade med ett antal adaptiva translationsinvarianta filter, mycket effektiva för identifiering av kännetecken i bild-data.

I det här projektet tillämpas egenutvecklade och anpassade ML-arkitekturer baserade på ovanstående metoder för att utföra komplexa analyser av PQ-data. Dessa kommer beskrivas närmare i relation till metod och tekniska resultat för vardera test.

3 Elkvalitet (PQ)

Kapitlet går igenom begreppet PQ, skillnaden mellan händelser och variationer och konsekvenserna av dålig PQ.

3.1 DEFINITION AV PQ

Bollen & Yu-Hua Gu (2006) definierar PQ som ett mått på kombinationen av kvaliteten på ström och spänning [10]. Ideal spänning kan närmast beskrivas som en sinuskurva med konstant amplitud och frekvens. På samma sätt kännetecknas ideal ström av konstant amplitud och frekvens, med tillägget att strömmens frekvens och fas ska vara detsamma som frekvensen och faser för spänningen. Alla avvikelser från detta ideala tillstånd kan definieras som en PQ-störning. Eftersom en förändring i ström påverkar spänningen och tvärtom, så är de två svåra att separera (ibid). Detta är en av anledningarna till uppkomsten av begreppet PQ.

PQ kan också definieras som välmåendet av elektrisk kraft för konsumentenheter definierade utifrån internationella standarder, till exempel IEC 61000-4-30. PQ är alltså ett mått på hur fri från störningar leveransen av el är, där dålig PQ påverkar elektrisk utrustning negativt. I Sverige har vi en förhållandevis god PQ med en relativt stabil leverans, men trots detta upplever vi kvalitetsrelaterad problematik. Eftersom vi kopplar upp allt fler enheter som också är känsligare för störningar, ökar betydelsen av och svårigheten med att upprätthålla en störningsfri leverans.

3.2 OLIKA TYPER AV PQ-STÖRNINGAR

En viktig distinktion som görs inom begreppet PQ är skillnaden mellan händelser och variationer. Händelser är plötsliga och med en början och ett slut, medan variationer kännetecknas av ett stabilt läge där kontinuerlig mätning krävs för att synliggöra dessa [10]. Händelser och variationer utgörs därmed av olika typer av störningar med olika karaktär och bör därför separeras inom begreppet PQ. Läsaren bör, för en ökad förståelse, känna till distinktionen mellan händelser och variationer, även om samlingsbegreppet PQ-störning används frekvent genom rapporten.

Tabell 1: Olika exempel på typer av PQ-störningar, relevanta för projektet

Händelser	Variationer
Spänningsdipp	Övertoner
Spänningshöjning	Transient
Avbrott	Flimmer

3.2.1 Händelser

PQ-händelser är plötsliga och med en början och ett slut. De definieras som avbrott, spänningshöjning och spänningsdipp i enlighet med Standard IEC-61000-4-30. En spänningshöjning detekteras när det kvadratiska medelvärde (Root Mean Square, RMS) av den uppmätta spänningen överstiger det nominella RMS-värdet

med 10%, medans en spänningsdipp definieras som en minskning av RMS-värdet med mer än 10%. Till sist definieras inträffandet av ett avbrott när RMS-värdet av spänningen är mer än 90% mindre än dess nominella RMS-värde [10].

En spänningsdipp är en multidimensionell elektromagnetisk störning, vars nivå bestäms av magnitud och varaktighet [11]. Magnituden av en spänningsdipp är värdet av restspänning under händelsen. Varaktigheten är tiden för vilken RMS-värdet stannar under tröskelvärdena för en spänningsdipp. Alltså, tiden för ett avbrott är ögonblicket från att RMS-värdet för spänningen faller under tröskelvärdet till ögonblicket då det reser sig över tröskelvärdet igen. En spänningsdipp är ofta associerad med förekomst och avslutning av ett kortslutningsfel, alternativt till extrem ökning i ström på grund av motorstart, *transformer energizing* etc (ibid). Den här typen av underliggande orsak är idag mer tydliggjord och studerad i den akademiska världen, medans den i praktiken är mer åsidosatt. Eneryield strävar för att överbrygga detta, vilket kommer att framgå senare i rapporten.

En spänningshöjning konstitueras av en ökning i spänningens RMS-värde, och dess varaktighet kan vara från en halv cykel upp till en minut. Spänningshöjningar är inte lika vanliga som spänningsdippar, men de är kända för att vara mer problematiska [12]. De negativa konsekvenser som uppkommer med dålig PQ beskrivs närmare senare i det här kapitlet. Situationen har hursomhelst blivit allt mer kritisk, exemplifierat av den senaste trenden inom industrin att öka driftspänningen hos exempelvis kraftomvandlare, någonting som pressar halvledare till dess bristningsgräns. Andra typiska underliggande orsaker för spänningsdippar är till- och fränkoppling av stora laster och *energizing capacitor* (ibid).

Avbrott är också en sorts PQ-händelse, vilket enligt IEEE Standard 1159 inträffar när spänningen understiger 10% av dess nominella värde. En annan IEEE standard, nämligen IEEE Standard 1366 har ett annat perspektiv, där avbrott definieras utifrån när uppströms skyddsfunktioner opererar. Två relevanta synsätt på ett fenomen, men den första definitionen tenderar bli mer relevant ur ett PQ-perspektiv. Långa avbrott är ett relativt ovanligt fenomen [13], men desto mer problematiskt och kostsamt när de väl inträffar [14]. Att upprätthålla en kontinuerlig och stabil leverans av elektricitet är därmed viktigt för elnätsägare.

3.2.2 Variationer

PQ-variationer är en kategori under begreppet PQ, som utgörs av mer tillfälliga typer av störningar, till exempel transienter, övertoner och flimmer. Det finns fler typer av PQ-variationer, men detta kapitel fokuserar på dessa tre.

Övertoner kännetecknas genom att spänning och ström förvrängs så att de avviker från sin sinusformade vågform [15]. Den här typen av störning är alltså synlig i såväl spänning som ström. Spänning förekommer i alla typer av laster i ett system och därmed kommer störningar i spänningen innebära en korresponderande störning i strömmen. Däremot innebär en störning i strömmen endast en korresponderande störning i spänningen om källans impedans har en gemensam

kopplingsimpedans. Typiska källor till övertoner är olinjära laster såsom ljusbågsugnar, lysrörsbelysning och likriktare (ibid).

Transienter definieras som mycket små och hastiga förändringar i spänning och ström [16]. Det finns ingen helt tydlig gräns, men störningar kortare än en cykel benämns generellt som transienter. Transienter kan bero på en mängd olika saker, men vanligast är blixtnedslag i ledningar eller komponentomkoppling av antingen nätverkskomponenter eller slutanvändarutrustning (ibid).

Flimmer är ett annorlunda PQ-fenomen, som är svårt att mäta, men desto lättare att upptäcka med blotta ögat, då det många gånger manifesteras av blinkande belysning. Flimmer beror på förändringar i RMS-värdet för spänning. Flimmer är alltså mer psykologiskt betingat än fysiskt, men en direkt konsekvens av fluktuationer i spänningen, där uppfattningen av flimret beror på spänningsvariationens vågform [17]. Flimmer är vanligt förekommande i svagare nät, och uppstår många gånger genom uppkoppling och franslag av laster [18].

3.3 KONSEKVENSER AV PQ-STÖRNINGAR

PQ-störningar skapar tekniska så väl som ekonomiska konsekvenser för olika aktörer kopplade till elnätet. Från ett nätägarperspektiv kan PQ-störningar påverka flertalet komponenter i nätet, såsom kablar, transformatorer och kondensatorer. De kan bland annat drabbas av kraftig uppvärmning, minskad energieffektivitet och tidigt åldrande. Kostnaderna för dålig PQ kan därför härledas till ökade energiförluster, reducerad livslängd av hårdvara och dysfunktionell utrustning. Dessutom kan PQ-störningar innebära leveransavbrott [19]. Detta avsnitt ämnar belysa hur PQ är relaterat till exempelvis energieffektivitet, slitage av hårdvara och produktionsstopp samt expansionen av förnyelsebar energi.

Dålig PQ innebär en reducerad effektfaktor, vilket påverkar sambandet mellan aktiv och reaktiv effekt. Med andra ord innebär detta en ineffektiv användning av elektricitet, där mer kWh än vad som egentligen är nödvändigt måste produceras. Det finns alltså en relation mellan effektiv produktion, distribution och förbrukning av energi och PQ, där kvaliteten på PQ (övertoner, obalans, ström på grund av reaktiv effekt etc.) bidrar till eventuell energiförlust. Det är svårt att uppskatta exakt storlek på dessa förluster, men man vet att de är relativa distortionsnivån, och i nära anslutning till hög distortionsnivå finns indikationer på förluster om 2-4% [20].

Det är värt att belysa att olika typer av störningar kan ge upphov till olika typer av hårdvarurelaterad problematik. Till exempel kan snabba transienter leda till kretskortsfel, där kretskortet förstörs helt, eller att det blir så pass medtaget att dess livslängd avsevärt förkortas. Transienter kan innebära komponentfel och kräva omstart av system. Övertoner och fasobalans innebär överbelastade motorer och transformatorer, med följaktig reducerad livslängd [21]. Spänningsdippar kan leda till *tripping* vilket kan orsaka rena avbrott eller skadad utrustning [22]. Höjningar i spänning kan leda till överhettning därmed och reducerad livslängd [23]. Dålig PQ kan alltså, från ett industri-perspektiv, medföra produktionsstopp och därmed all

den kostnad som kommer med oplanerade driftstopp, produktionsbortfall och skadad utrustning [21].

Det är evident att dålig PQ kan få stora negativa konsekvenser för flertalet aktörer på en mängd olika sätt. Dessutom, vid anslutning av förnybar elproduktion till distributionsnätet kan PQ-störningar uppstå. Till exempel skapar PV-paneler spänningsvariationer när de är anslutna till lågspänningsnätet, och omvandlarfrekvensen för omriktare i vindkraftverk orsakar övertoner [24]. I och med detta riskerar PQ att påverka den pågående expansionen av förnyelsebar energi negativt.

4 Nuvarande arbetsmetoder

Vid tre tillfällen har projektdeltagare och referensgrupp samlats för att genomföra workshops. Ett av syftena har varit att kartlägga nuvarande arbetsmetoder relaterade till PQ. I kapitlet beskrivs arbetsmetoderna för mätning, datahantering och analys.

4.1 MÄTNING

Mätning av PQ sker i dagsläget med stationära PQ-mätare utplacerade på elnätet och med portabla PQ-mätare för tillfällig användning i problematiska områden.

Stationära PQ-mätare placeras främst i nätstationer ute i distributionsnätet och regionnät. Antalet PQ-mätare och placering av dessa varierar mellan nätägare. Det kan också förekomma PQ-mätare i sammankopplingspunkter för vind- och solkraftverk, eftersom dessa ofta orsakar PQ-problem. Jämtkraft, som är en av projektets deltagande nätägare, har ca 50 PQ-mätare utspridda i mellan- och högspänningsnät.

Som framkommit ur projektet och som också beskrivs ytterligare av Sahoo (2019) finns idag ett flertal företag som erbjuder klass-A mätning av PQ över olika spänningsnivåer. Klass-A definieras enligt IEC 61000-4-3, och anses tillhandahålla noggranna och precisa mätningar [25]. I det här projektet har främst data från klass-A-mätningar använts. Värt att notera är dessutom att datan som använts i projektet, kommit från olika leverantörer av PQ-mätare och att dessa inte kommunicerar med varandra genom någon form av standardiserade protokoll. Dessutom sparas dataloggar i leverantörspecifikt format vilket komplicerar exporten av data från olika nätägars mätningar. I det här projektet har därmed en rad olika tillvägagångssätt för dataexport testats, vilket specificeras i *kapitel 8. Reflektion*.

Portabla mätare används också av projektets deltagare, men dessa finns i begränsat antal och används sporadiskt. Dessa beskrivs dock som ett viktigt verktyg när det inkommit klagomål från kunder i framför allt lågspänningsnätet, där det för närvarande råder begränsad övervakning genom stationär mätning. Olika leverantörer av dessa portabla mätare förekommer, men ofta är de från samma leverantör som tillhandahåller respektive nätägars stationära mätare. Data från tillfällig mätning samlas i regel in under en vecka eller mer, och sparas i olika filformat beroende på leverantör av mätinstrumentet. Detta kan, likt de stationära mätvärdena, vara problematiskt om datan ska användas av annan part för exempelvis forskning och utveckling.

Arbetet med mätning styrs av förordningar snarare än kostnader. Exempelvis definierar EN 50160 de krav som finns gällande parametrar för spänning av elektrisk energi i offentliga distributionssystem, samt IEC 61000-4-3 de krav som föreligger beträffande mätmetoder för PQ-parametrar för ström. Vidare finns en mängd standarder för mätning av exempelvis flimmer, övertoner och andra PQ-störningar.

4.2 DATAHANTERING

Nätägares hantering av PQ-data är ofta beroende av dess respektive leverantör av PQ-mätare och övervakningssystem. Hur frekvent och vilka parametrar som registreras och sedan lagras av nätägare beror på PQ-mätarens inställning. De PQ-störningar som registreras, sparas sedan i en databas. Var databasen är belägen varierar för projektets olika deltagare. Det kan röra sig om en lokal server belägen hos nätägaren, en server hos leverantören av PQ-mätare och övervakningssystem, eller en kombination av de båda.

Databasstrukturen hos olika nätägare är också uppbyggd efter de unika filformat och dedikerade PQ-mjukvarorna. Detta innebär att det krävs intern kunskap hos respektive nätägare om var data är lagrad, vilka filformat som används och hur export av filer kan utföras. Kunskapen om detta är ofta relativt låg, vilket innebär att det uppstår utmaningar vid exempelvis extern dataanalys. Dessa utmaningar beskrivs utförligt i *kapitel 8. Reflektion*.

4.3 ANALYS

Eftersom nätägares viktigaste uppdrag är att upprätthålla en stabil och pålitlig leverans av el, används PQ-analys som ett verktyg för att överblicka nätet, och säkerställa att satta standarder upprätthålls. Analys av PQ-störningar görs även för att identifiera vem som är ansvarig för en specifik störning och därefter bedöma nödvändig åtgärd, vilket är i linje med standarden EIFS 2013:1 som beskriver ansvarsfördelning för upprätthållandet av god PQ.

Operatörer hos de nätägare som deltagit i projektet arbetar främst genom det befintliga SCADA-systemet, men har tillgång till specifik PQ-mjukvara. PQ-mjukvaran ger en överblick över utsatta PQ-mätare på nätet, och listar de PQ-störningar som registrerats av respektive mätare. Mjukvaran är kapabel att, på en övergripande nivå, klassificera olika störningar, som i regel sparas som RMS-värden eller vågformer för spänning- och strömvärden, även om det senare ibland dessvärre saknas.

All PQ-data som lagras på en dedikerad server är klassificerad baserat på ett signalbehandlingsverktyg som extraherar kännetecken utifrån på förhand satta tröskelvärden. Det finns stora begränsningar i analysen, och många gånger krävs domänexpertis för att kunna dra slutsatser utifrån den information som finns tillgänglig. Till exempel krävs manuellt arbete för att förstå grundorsaken till PQ-störningar.

Som komplement används i vissa fall en så kallad PQ-rapport, vilken kan genereras från PQ-mjukvaran. Rapporten synliggör de PQ-störningar som skett och om de faller inom acceptabel standard. Befintliga rapporter ger dock endast en övergripande analys och dess pålitlighet är av varierande grad. Som tidigare nämnts krävs därmed manuell handpåläggning från erfaren person för att kunna dra slutsatser utifrån den genererade rapporten. Dessutom utförs generellt analys av PQ-störningar endast vid större problem, och att kontinuerligt analysera fler PQ-störningar är idag en allt för tidskrävande process.

5 Behovsanalys

Många elnätsägare har gott om PQ-mätare utplacerade på sina elnät med tillhörande mjukvara som analyserar och visualiserar den insamlade datan. Det finns goda möjligheter att fortsätta fördjupa och automatisera denna analys för att, som belyst tidigare i rapporten, reducera det manuella arbete som fortfarande krävs i vissa fall.

För att undersöka de behov som elnätsägare upplever ställdes följande frågor under en workshop:

- Vilka utmaningar upplever ni i relation till PQ, med fokus på datainsamling och analys?
- Tror ni att en detaljerad grundorsaksanalys av PQ-störningar skulle skapa värde till era verksamheter? (vilka händelser)

5.1 UTMANINGAR RELATERADE TILL ELKVALITET

De utmaningar som elnätsägare belyste under en workshop relaterade till PQ presenteras i tabell 2 och 3. Det är tydligt att det är viktigt att identifiera vad som orsakar en specifik PQ-störning och från vilken riktning de kommer (uppströms/nedströms). Bland andra utmaningar som inte är starkt kopplade till PQ är hantering av effektoppar och planering av elnät prioriterade. Insikterna från behovsanalysen har legat till grund för inriktningen av den ML-baserade analysen i projektet.

Tabell 2: Utmaningar som elnätsägare upplever

Utmaningar relaterade till PQ	Prioritering
Bevisa vem som är skyldig till en viss PQ-störning	Hög
Identifiera vad som orsakar en specifik PQ-störning	Hög
Identifiera riktningen som en störning kommer från (ovan- eller nedifrån)	Hög
Identifiera problem i komponenter och hårdvara tidigt och om deras livslängd och prestanda påverkas av detta	Hög
Förstå tillståndet på kablar och när de behöver underhåll	Hög
Klassificera jordfel och upptäcka felande kraftledningar	Medium
Identifiera PQ-störningar som inte upptäcks med nuvarande lösningar	Medium

Tabell 3: Utmaningar (orelaterade till PQ) som elnätsägare upplever

Andra utmaningar	Prioritering
Hantera effektoppar	Hög
Planera och dimensionera elnätet mer noggrant	Hög
Energiförluster	Medium
Förstå när en byggnad är utan ström	Medium
Stöld av elektricitet	Medium

5.2 VÄRDET AV ATT FÖRSTÅ PQ-STÖRNINGARS GRUNDORSAK

Att genomföra en grundorsaksanalys av PQ-störningar innebär att föreslå vad en störning beror på. I dagsläget görs detta manuellt. Genom att automatisera analysen i så hög grad som möjligt, kan både det manuella arbetet minska och kvaliteten på arbetet höjas. Ett första steg är att koppla en enskild störning till en möjlig grundorsak, till exempel motorstart eller kabelfel. Enligt elnätsägarna är det viktig information av främst två anledningar:

1. Det gör det lättare att åtgärda grundorsaken till en PQ-störningar, vilket gör elnätet stabilare och gör det enklare att följa regleringar.
2. Det gör det lättare att identifiera vem som är skyldig till en PQ-störningar, vilket gör att rätt aktör får ta konsekvenserna för denna.

Olika PQ-störningar leder till olika konsekvenser. I tabell 4 listas dessa efter prioritering av elnätsägare.

Tabell 4: Rangordning av PQ-störningar

Prioritering	PQ-störningar	Konsekvens
1	Spänningsdippar	Leder till skador på bland annat elektronik, styrsystem och datorer. Dessutom driftstörningar i frekvensomriktare mm.
2	Transienter	Svåra att identifiera och förstå ursprunget på i dagsläget. Ger indikation om kabelfel och isoleringsproblem.
3	Partiella urladdningar	Skapar förståelse för kablars tillstånd och livslängd.
4	Jordfel	För att förstå nätets hälsa och skapa stabilitet nära känsliga kunder.
5	Övertoner	Krävs snabb analys för att brytare inte ska slå ifrån.

6 Analys och resultat

I det här avsnittet presenteras tillvägagångssättet för datainsamling och analys samt de tekniska resultaten.

6.1 DATAHANTERING

Ett stort behov vid ML-driven analys är tillgång till stora dataset för att optimera inlärning samt test av specifik algoritm. Eneryield har därför samlat in och förbehandlat PQ-data för att möjliggöra en effektiv analys.

6.1.1 Insamling av data

Den data som använts i projektet samlades in i samarbete med ett antal aktörer som har installerat PQ-mätare på elnätet (se tabell 5). Detta var en större utmaning än planerat, då det inte existerar standardiserade protokoll för export av data eller neutral plattform för datahantering. Därför utreddes olika metoder för export som testades tillsammans med nätägare, allt från att exportera hela databaser till att exportera enskilda störningar manuellt direkt från PQ-mjukvara. Detta genomfördes med varierande framgång och berörs närmare under kapitel 8.

Reflektion.

Tabell 5: Insamlad data och utvärdering av denna

Dataset	Beskrivning	PQ-störningar	Utmaningar	Insikter
Göteborg Energi	Data lagrad dels på lokal server internt och dels på server hos PQ-leverantör Data exporterad som SQL-fil Ingen access till PQ-mjukvara	- Spänningsdippar - Övertoner - Jordfel - Transienter - Avbrott	Eftersom det är en kopia av hela databasen, är det svårt att hitta relevanta filer och exportera effektivt.	En mindre del av datan har använts. Fortsatt arbete krävs för att finna en väg att använda SQL-fil.
Härryda Energi	Lagrad på lokal server internt Data exporterad som SQL-fil Ingen access till PQ-mjukvara	Ingen data använd för träning eller test	Eftersom det är en kopia av hela databasen, är det svårt att hitta relevanta filer och exportera effektivt.	Fortsatt arbete krävs för att finna en väg att använda SQL-fil.
E.On	Data exporterad manuellt, störning för störning. 35 störningar	- Spänningsdippar - Transienter - Avbrott	Mestadels RMS värden Saknar verktyg för storskalig dataexport	Storlek på dataset användbar för test av algoritmer
Jämtkraft	Data lagrad på lokal server. Access given till PQ-mjukvara där data har exporterats manuellt.	- Spänningsdippar - Transienter - Avbrott	Tidskrävande process att samla in tillräcklig data. Många störningar saknar riktning	Största datasetet som använts God mängd data för grundorsaksanalys
Unipower	Access till Unipower mjukvara och 2 mätare av liknande funktionalitet som övriga datakällor Data över 12 år	- Spänningsdippar - Övertoner - Jordfel - Transienter - Avbrott	Endast access till två olika mätare	Exportmodul tillgängliggjorts av Unipower vilket ledde till snabb och storskalig nedladdning av PQ-störningar

Den data som använts för träning, validering och test i projektet är fördelat över spänningsdippar, spänningshöjningar, jordfel, transienter och avbrott. Tabell 9 under avsnittet Grundorsaksidentifiering visar fördelningen mellan de PQ-händelser som användes för analys och tydliggör den ojämna fördelningen av totalt ~1800 PQ-händelser. Valet av vilka PQ-störningar som ingår i analysen beror på vad som finns tillgängligt i nuvarande system samt kapitel 5 Behovsanalys.

Den information som funnits till hands för varje enskild PQ-störning är baserad på satta tröskelvärden, definierade i den PQ-mjukvara som respektive nätägare använder sig av. Den information som generellt finns tillgänglig ses i tabell 6. Mängden information för vardera PQ-störning i använd data varierar dock. I de fall information saknas är det oftast beträffande riktning och kommentar. Den data

som använts har en samplingsfrekvens på 0,6kHz-12,8kHz, längd om 2-3 sekunder och pre-trig tid motsvarande 0,1 sekunder.

Tabell 6: Tillgänglig information i befintlig PQ-mjukvara

Mätplats	Tid	Fas	Varaktighet	Nivå Spänning	Referens- spänning	Riktning	Kommentar
----------	-----	-----	-------------	------------------	-----------------------	----------	-----------

Energifyield har använt sig av vågformer för spänning- och strömnivåer i sin analys. En fördel med att analysera just vågformer, framför RMS-värden, är att de innehåller mer av den ursprungliga signalen. Alltså, mindre filtrering och därmed en högre detaljnivå, vilket ger en mer verklighetstrogen bild av vad som faktiskt sker på elnätet. Data som är så nära rådata som möjligt är många gånger fördelaktigt vid användning av ML, eller andra typer av AI-lösningar, vilka har som mål att utföra mönsterigenkänning, anomalidetektion, modellvalidering eller liknande. Detta då nödvändiga detaljer kan gå förlorade i en komprimerad eller på annat vis behandlad signal.

6.1.2 Förbehandling

I syfte att möjliggöra effektiv praktisk tillämpning i tidskritiska system användes minimal förbehandling av råa, men standardiserade, vågformssignaler av PQ-störningar, för att sedan applicera automatisk egenskapsdetektering på input data. Data delades in i separata mängder för träning, validering och test. Detta för att säkerställa att "overfitting" ej inträffat, vilket betyder att modellen inte generaliserar väl från träningsdata till osedd data. Flera åtgärder togs för att algoritmerna skulle generalisera väl över en stor mängd data från olika dataset och därmed vara gångbar i flera sammanhang. Ingen simulerad data har använts i projektet. För att minimera den beräkningskraft som behövs för att köra algoritmerna användes minimal förbehandling.

6.2 ANALYS MED ML-BASERADE METODER

Här presenteras de ML-metoder som har använts samt de tekniska resultat som uppnåtts. I *figur 2* ges en översikt av den analys som gjorts och hur de olika analyserna relaterar till varandra.



Figur 2: Översikt av genomförda analyser och hur de relaterar till varandra

Ett delsyfte med detta projekt är att belysa ytterligare användningsområden för ML-baserad analys av energirelaterad data. I behovsanalysen (se *kapitel 5. Behovsanalys*) belystes utmaningarna att hantera effekttoppar samt att planera och dimensionera elnät. Därför har även ML-metoder för att analysera och förutse energiförbrukningsdata testats, utöver projektets primära fokus kring PQ.

6.2.1 Klassificering av PQ-störningar

Den mest grundläggande analys som utfördes var automatisk klassificering av PQ-störningar. Det innebar att identifiera till exempel spänningsdippar, spänningshöjningar och transienter med hög träffsäkerhet och utan manuell handpåläggning (se *figur 3*).



Figur 3: Översikt för klassificering av PQ-störningar

Metoden baseras på en egenutvecklad arkitektur av faltningsvävverk/CNN och Long Short Term Memory (LSTM), vilket är en speciell typ av RNN. LSTM används som en grundläggande byggsten för att utvinna kännetecken och klassificera. Varje lager i det neurala nätverket är utvecklat för att kategorisera viss information, förfinar och skickar vidare till nästa lager. Till exempel letar det första lagret efter spänningsnivåer och det andra lagret ser hur stor förändringen är och det tredje extraherar i vilken fas det sker, medan det sista lagret tar in hela vågformens karaktär. Det neurala nätverket sätter samman informationen från de olika lagren, och känner igen olika typer av PQ-störningar och kan klassificera dessa.

Med tanke på det långsiktiga målet att möjliggöra implementering i en realtidsapplikation användes minimal förbehandling av data. Detta innebär att metoden tar in registrerade vågformer som de syns i befintlig PQ-mjukvara, utan att behöva tunga eller tidskrävande beräkningsmetoder för att städa, minska eller på andra sätt ändra datan.

En stor fördel med denna metod är att den kan lära sig kännetecken i vågformer utan att behöva ta hänsyn till, på förhand, manuellt satta trösklar. Med andra ord kräver metoden inte några manuellt skapade kännetecken, utan klarar att automatiskt lära sig att identifiera användbara kännetecken i vågformer. Detta minimerar risken för felaktig klassificering på grund av felaktigt inställda


tröskelvärden. Det här tillvägagångssättet är fördelaktigt vid hantering av stora mängder data, där ML-tekniker är att föredra framför traditionella metoder. Detta då ML-tekniker är anpassade för mönsterigenkänning och därmed väl lämpade för klassificering, där algoritmerna hela tiden kan utvecklas av kontinuerligt utökad mängd data.

Den data som användes var obalanserad i den mening att träningsdata hade övervikt av spänningsdippar. Datasetet delades slumpmässigt upp i två delar, 80% användes för träning, och 20% för testning. Detta för att metoden skulle generalisera väl över en bred variation av data och sammanhang.

Under 6.2.3 presenteras några exempel av klassificerade händelser tillsammans med deras identifierade grundorsaker.

Tekniska resultat

Tillämpning av en faltningsnätverkarkitektur för störningsklassificering visade sig ge stabil konvergens under träning, och gav i slutändan en mycket hög träffsäkerhet om **99%**. Träffsäkerhet och felmått under träning redogörs i *Graf 1*.



Graf 1: Träffsäkerhet på och felmått under träning för störningsklassificering. Systemet når snabbt hög träffsäkerhet om 99% på testdata, och lågt fel, med stabil konvergens.

6.2.2 Identifiering av PQ-störningars riktning

Att identifiera en PQ-störnings riktning innebär att bestämma om dess ursprung är uppströms (närmare högspänningsnätet) eller nedströms (närmare lågspänningsnätet).

Identifiering av riktning är någonting som redan i viss mån görs i existerande analys, men det har framkommit att pålitligheten i vissa fall är begränsad. Det estimeras att ursprunglig annotering av tillhandahållna data är ca **80%** korrekt. Dessutom saknar flera PQ-händelser annotering för riktning, då nuvarande metoder har svårt att avgöra detta. Därför utfördes ML-baserad analys för att avgöra riktning av PQ-händelser. Detta gjordes med hjälp av utvecklade metoder för förberedning och detektering av drag och mönster i vågformer. Dessa baseras på en CNN-arkitektur där problemet blir en binär klassificering av datapunkter som ska kategoriseras som antingen uppströms eller nedströms. Detta fungerar

genom att den råa vågformen analyseras av ett antal filter i flera lager. Varje filter har under träningsfasen lärt sig att specialisera sig på att upptäcka olika typer av kännetecken som, när de beaktas tillsammans, effektivt kan användas för att bestämma riktningen för olika PQ-händelser.



Figur 4: Process för identifiering av PQ-störningars riktning




Det dataset som användes för analys var väl balanserat mellan upp- och nedströms (se tabell 7).

Tabell 7: Distribution av data för riktning

Riktning	Antal störningar	Typ av störning
Uppströms	217	Spänningsdipp
Nedströms	182	Spänningsdipp (181), Jordfel (1)


För att ytterligare öka förståelsen för prestandan utfördes en manuell inspektion av ett fåtal slumpmässigt utvalda händelser där annoteringen från tillhandahållen data ej stämde överens med analysen från det föreslagna fältningsnätverket. Inspektion av tre sådana slumpmässigt utvalda händelser (se Tabell 8) utfördes av expert inom ämnet genom analys av övertoner tillsammans med grundfrekvens av strömmen före och under PQ-händelser/variationer. Resultatet var att den riktning bestämd av det föreslagna fältningsnätverket var korrekt för två av dessa. Detta är för få inspektioner för att dra några generella slutsatser om den faktiska prestandan, men indikerar att den i praktiken kan vara högre än nuvarande träffsäkerhet. Det finns här ett behov av att ytterligare undersöka graden av felannotering; främst bland de händelser där riktningen inte överensstämmer mellan metoderna men även återstående delen av datan.

Tabell 8: Tre slumpmässigt utvalda händelser bland de fall där Energyields föreslagna fältningsnätverk ej motsvarade den annotering tillhandahållen av Unipower. Efter manuell inspektion av dessa utförd av ämnesexpert visade det sig att annotering var inkorrekt för två av dessa, för vilka riktningen identifierad av fältningsnätverket var korrekt.

Vågform	Riktninganalys
	Initial annotering: Uppströms Energyields metod: Nedströms Manuell inspektion: Uppströms
	Unipower annotering: Nedströms Energyields metod: Uppströms Manuell inspektion: Uppströms
	Unipower annotering: Nedströms Energyields metod: Uppströms Manuell inspektion: Uppströms

Tekniska resultat

En faltningsnätverksarkitektur visade bäst konvergens för detta problem, inlärningsprocessen visas i *Graf 2*. På valideringsdatan uppnås en träffsäkerhet om maximalt ~85%, och stagnerar kring ~80%. Notera att denna träffsäkerhet avser hur väl den föreslagna metoden presterar relativt de annoteringar som tillhandahållits, som uppskattats vara ~80% korrekta.




Graf 2: Träffsäkerhet (y-axel) på tränings- (blå) och valideringsdata (orange) för föreslagen metod för riktningssidentifiering av händelser under inlärningstiden (x-axel).

6.2.3 Grundorsaksidentifiering

Projektets primära mål är att ta fram ett proof-of-concept för ML-driven grundorsaksidentifiering av PQ-störningar. Grundorsaksidentifiering innebär att föreslå en möjlig orsak till att en PQ-störning skapats, till exempel en motorstart.


Prioritering över vilken typ av störning att fokusera analysen på, baserades på störningarnas generella problematik, behovsanalysen (se kapitel 5. *Behovsanalys*) och Eneryields interna kompetens. Med bakgrund av detta föll valet att i det här projektet fokusera på spänningsdippar och transienter.

I *figur 5* ses en övergripande process för proof-of-concept för ML-driven grundorsaksidentifiering. I det här exemplet har en spänningsdipp spelats in av befintlig PQ-mätare. Grundorsaksanalysen baseras på den övergripande klassificeringen, där analysen utvidgas och inkluderar orsak, till exempel en motorstart.



Figur 5: Överblick över metoden för grundorsaksidentifiering

Även denna ML-arkitektur är baserad på LSTM och minimal förbehandling av indata. Processen som presenteras i *Figur 5* exemplifierar analysen av en spänningsdipp, men metoden är densamma vid grundorsaksidentifiering av transienter. I *figur 4* demonstreras det föreslagna systemet för grundorsaksanalys. Råa vågformer tillhörande inspelningar från trefassystem matas genom separata kanaler till neuronnätet. Bäst prestanda uppnåddes med en arkitektur bestående av tre lager av LSTM-neuronceller.



Figur 4: Upplägg för grundorsaksidentifiering. Olika faser matas via separata kanaler in i LSTM-arkitekturen som består av tre neuronlager.

Under träningsfasen (*figur 4*) justeras parametrarna i LSTM-arkitekturen att optimalt analysera träningsdata baserat på den data som tillförs. Samtidigt observeras prestandan på den separata testdatan.

I utvecklingsfasen av denna typ av analys är förarbetet med annoteringar av PQ-störningar centralt. Det innebär att på förhand knyta en typ av grundorsak till en viss typ av anomali i vågformens olika faser. Det krävs också att det finns en viss mängd datapunkter, så att träffsäkerheten blir tillräckligt hög. Då blir analysen tillförlitlig och användbar.

Analysen fördelar alla PQ-händelser från tillgängliga dataset först i händelsetyp, spänningsdipp, transient, etc. För att fortsättningsvis fördela varje händelsetyp i underkategorier som beskriver grundorsaken. I *Tabell 9* presenteras en sammanfattande överblick av den data som använts för att träna och testa systemet. Som exempel kan en PQ-störning kategoriseras som händelsetyp: spänningsdipp, och grundorsak: kortslutning på grund av fas till jord. Detta presenteras ytterligare i *Tabell 10*, där vågform, ursprunglig klassificering och grundorsak presenteras. Ytterligare vad som är unikt med denna metod är att PQ-störningar som beror på varandra (två PQ-störningar som sker en efter en annan) identifieras och tydliggörs av metoden, se *Tabell 10, rad 3*. I samma tabell åskådliggörs även fördelning mellan de olika händelsetyperna och dess grundorsaker. Detta ger dels en överskådlig blick över hur frekventa vissa typer av grundorsaker är, men det visar också en viss skillnad mellan ursprunglig klassificering och klassificering med föreslagen metod. Värt att notera är att den här typen av ganska tidskrävande annotering inte är någonting som man behöver göra när ML-metoderna väl har tränats, utan det är endast i tidig utvecklingsfas som kräver manuell handpåläggning.




Tabell 9: Överblick fördelning av PQ-störningar och dess grundorsaker

Händelsetyp	Fördelning enl. annotering	Fördelning enl. föreslagen metod	Grundorsaker	
Spänningsdipp	80%	87%	Transformator (Saturation, energization, deenergization)	26%
			Fel (kabelfel, matningsfel, trefasfel etc.)	44%
			Kortslutningsfel (enfasfel till jord, tvåfas till jord, trefasfel till jord etc.)	23%
			Motorinduktion	7%
Övertoner	0,3%	0%	n/a	n/a
Avbrott	2,7%	3%	Icke-fel	50%
			Fel	29%
			Motor	21%
Transienter	17%	10%	Capacitor energization	62%
			Capacitor deenergization	31%
			Switching	7%

Efter träningsfasen avslutades utfördes en noggrannare manuell inspektion av systemets beteende. Det noterades att det föreslagna systemet baserat på ML i många fall ger betydligt mer insiktsfulla och korrekta analyser jämfört med den


som gjorts ursprungligen, som i flera fall inte är korrekt. Se exempel i tabellen nedan. Fler exempel återses i *Bilaga A*.

Tabell 10: Exemplifiering av hur nuvarande klassificering skiljer sig mot Eneryields analys.

Vågform/RMS-värde	Ursprunglig klassificering	Eneryields analys
	Transient	Klassificering: Transient Grundorsak: Capacitor energization
	Transient	Klassificering: Transient Grundorsak: Capacitor deenergization
	Transient	Klassificering: Spänningsdipp Grundorsak Trefasfel i distributions-system Följt av transformer saturation

Tekniska resultat

Som kan avläsas i *Graf 3* så når systemet en träffsäkerhet om **95%** för grundorsaksidentifiering på testdatan.



Graf 3: Träffsäkerhet på och felmått under träning för grundorsaksidentifiering. System når 95% träffsäkerhet på testdatan.

6.2.4 Förutse energikonsumtion


I behovsanalysen (se kapitel 5. *Behovsanalys*) identifierades ett behov att, förutom analysera data som relaterar till PQ, även förutse energiförbrukning. Det är viktigt vid planering av elnät eller lasthantering.

För att utföra denna typ av analys har data från Jämtkraft använts. Data laddades ned från PQ-mätare i form av vågformer för den aktiva effekten (P), reaktiva effekten (Q) och den skenbara effekten (S). Längsta dataintervall som använts från en enskild mätare sträcker sig över 1 år med en samplingsfrekvens om 10 minuter. En LSTM arkitektur tränades för förutsägning på en del av denna data, och testades på ett separat tidsintervall, som delvis visas i *Graf 4* och 5.

Data predikterades för 10 minuter respektive 5 timmar framåt i tiden. För att förutsäga 10 minuter framåt räcker det att använda datapunkter 1-2 timmar tillbaka i tiden. För att förutsäga 5 timmar krävs datapunkter från ca 6 timmar, till ett dygn bakåt i tiden. Horisonten av förutsägelsen kan anpassas beroende på applikation, men träffsäkerheten sjunker ju längre den är.


Tekniska resultat

De tester som utfördes i detta projekt påvisade mycket goda resultat för att förutspå både snabba och längre förändringar i trender av energiförbrukning. Som kan ses i *graf 4* utfördes en förutsägelse av energiförbrukning, 10 minuter fram i tiden, med en noggrannhet med ~ 0% felestimering.




Graf 4: Noggrannhet för att förutse energiförbrukning 10 minuter framåt i tiden.

Ytterligare ett test utfördes med en förutsägelse av energiförbrukning 5 timmar fram i tiden. Resultatet visas i *graf 5* nedan. I detta test uppnåddes en noggrannhet med ~3% felestimering.



Graf 5: Noggrannhet för att förutse energiförbrukning 5 timmar framåt i tiden.




Graf 6: Felmått för förutsägning under inlärningsprocessen

7 Tillgängliggörande av resultat

För att de resultat som framkommit i projektet ska kunna användas har möjliga sätt att tillgängliggöra resultatet undersökts och möjligheten till implementering i befintliga system. Här inkluderas en så kallad Minimum Viable Product (MVP).

7.1 MINIMUM VIABLE PRODUCT: PQ-RAPPORT

En Minimum Viable Product (MVP) är en version av en produkt med precis tillräckliga funktioner för att tidiga användare ska bli nöjda och kunna tillhandahålla feedback för framtida produktutveckling.



Figur 5: Framsida för analysrapport

För att åskådliggöra det värde som den ML-baserade PQ-analysen kan skapa, har en exempelrapport i PDF-format, som tillgängliggör och ger en överblick för den ML-baserade PQ-analysen, utvecklats (se figur 5 för framsida och bilaga B för full rapport). Rapporter i PDF-format, som sammanfattar PQ-händelserna vid en viss mätare på elnätet, används ofta av nätägare vid elkvalitetsanalys.

Voltage dips

Date & time	Root-cause	Direction	Event figure
2020-01-05 16:45	Transformer energization	Upstream	
2020-01-07 16:14	Three phase fault in distribution system. Followed by transformer saturation	Upstream	
2020-01-13 01:11	Autoreclosure in distribution feeder	Upstream	
2020-01-24 07:23	Transformer saturation	Downstream	

Figur 6: Exempelsida i analysrapport

Rapporten är indelad i fyra delar: Spänningsdippar, transienter, avbrott och jordfel. I vardera del listas de relevanta PQ-störningarna med föreslagen klassificering, grundorsak och riktning (se exempelsida i figur 6). Det här projektet har fokuserat på spänningsdippar och transienter, men andra typer av fel synliggörs också i rapporten.

De PQ-rapporter som i dagsläget används hos nätägare följer standarden EIFS 2013:1 och innehåller ytterligare typer av analys. Detta är borttaget från denna MVP för att fokusera och åskådliggöra på det bidrag som detta arbete kan ge.

Tanken med den här nya rapporten är att automatisera processer som idag är tidskrävande och beroende av manuellt arbete. Samtidigt ska den nya informationen bidra till en bättre förståelse av elnätets generella hälsa, effektivare åtgärder för att eliminera störningar samt som underlag för att enklare förstå vem som är ansvarig för en störning. Rapporten ska kunna genereras vid behov, och eftersom analysen sker ständigt och automatiskt finns ingen begränsning.


7.2 IMPLEMENTERING I NUVARANDE SYSTEM OCH IT-SÄKERHET

För att få full nytta av den ML-baserade analysen bör den implementeras i en digital plattform som används kontinuerligt av nätägare. Det finns flera möjligheter att åstadkomma detta, med olika för- och nackdelar, bland annat relaterat till IT-säkerhet.



Figur 7: Alternativ 1: Implementera ML-metoder i nuvarande system

Att implementera ML-metoderna i existerande SCADA eller PQ-mjukvara är ett alternativ (se figur 7). En fördel är att det inte krävs ny mjukvara, utan det räcker att uppdatera den tidigare. Detta är smidigt ur slutanvändarsynpunkt, men kan vara komplext att genomföra, då även leverantörerna av dessa system behöver engageras. IT-säkerheten kan bibehållas då det är ett slutet system där all data hanteras utan att skickas till tredje part. Att implementera ML-metoder i mjukvara som inte är anpassad för att utföra tunga beräkningar kan vara en utmaning.



Figur 8: Alternativ 2: Tillgängliggöra ML-metoder med API

Ett annat alternativ är att genomföra analysen på externa servrar genom ett API (se figur 8). Enskilda PQ-händelser kan då skickas, krypterade och anonymiserade (endast vågformen - ingen metadata), till en extern server där klassificering och grundorsaksanalys genomförs för att sedan skickas tillbaka till den plattform som används av nätägaren. Fördelen med denna metod är att stora mängder data inte behöver processas hos nätägaren, utan att det kan göras av en aktör med servrar anpassade för ML-analys. En nackdel ur IT-säkerhetssynpunkt är att data behöver skickas till tredje part, men det går att säkra upp med kryptering.

8 Reflektion

Det här avsnittet reflekterar över projektet och de utmaningar som uppstått och vilka insikter som detta har resulterat i. Vidare diskuterar avsnittet de möjligheter relaterat till analys som redan finns och som kommer med den stegrande digitaliseringen av sektorn i fråga, i strävan mot framtidens smarta elnät.

8.1 UTMANINGAR - INSIKTER FRÅN PROJEKTET

Främst har utmaningar i projektet berört frågor kring export av data och datans kvalitet. Även om en utmaning är påfrestande i stunden, så kommer den i retrospektiv innebära flertalet nya insikter och i förlängningen belysa fokus för framtiden, vilket också är en viktig del av projektet. Speciellt i projekt likt detta, som bryter ny mark och ska verka kunskapsbyggande. I det här avsnittet resoneras det kring de olika utmaningar som har uppstått under projektets gång.

8.1.1 Export av data

Datainsamling och tillgång till data har varit en påtaglig utmaning under projektet. Att exportera stora mängder data har visat sig vara en mer komplex och tidskrävande procedur än på förhand förmodat. Aggregering av data är en flaskhals och det är viktigt att överbrygga den här utmaningen för storskalig implementering av framtida datadrivna lösningar. För att kringgå avsaknaden av standardiserade protokoll för insamling av PQ-data har tre alternativa tillvägagångssätt testats:

1. Kopiera hela databasen (SQL-fil)
2. Exportera PQ-störningar manuellt ur PQ-mjukvara (Excel-filer)
3. Dedikerad exportmodul (Comtrade-filer)

I *alternativ 1* exporterades data som större SQL-filer (kopia av hel databasstruktur). Detta tillvägagångssätt löste problemet med att behöva exportera varje PQ-störningar manuellt, en åt gången. Dock krävdes avsevärd tid och kunskap för att förstå databas-strukturerna och utvinna specifika datapunkter. Återskapandet av databasen påbörjades under projektet, men arbetet visade sig vara tidskrävande och andra alternativ för att få tillgång till nödvändig data prioriterades för att möta deadline.

Alternativ 2 innebär export av PQ-störningar direkt ur dedikerad PQ-mjukvara. Detta krävde dock omfattande manuellt arbete för att exportera en PQ-störning åt gången. För export av vågformer användes excel-format. Det här tillvägagångssättet möjliggjorde projektets slutförande, men är inte en långsiktigt hållbar lösning.

I *alternativ 3* användes en specialprogrammerad exportmodul som automatiskt kan exportera flera PQ-störningar åt gången. Detta var något som tillhandahölls i projektets senare del. Det här tillvägagångssättet är i dagsläget mjukvaruspecifikt, men kan vara ett viktigt steg mot en neutral plattform som möjliggör extern analys.

För att kringgå detta hinder vid fortsatt utveckling, forskning eller andra fall då nätägare vill använda sin PQ-data i någon form av extern analys, är det därmed av intresse att fortsätta undersöka lösningar för ett uniformt sätt att hantera data på. En möjlig lösning som kan studeras vidare är en standardiserad databas (till exempel SQL) med strukturer för att beskriva metainformation (till exempel frekvens eller pre-trig-tid). En annan kan vara praktiska import- och exportlösningar som säkerställer att standarderna upprätthålls i databasen och att önskade inspelningsintervall eller partier med data enkelt och effektivt exporteras.

8.1.2 Datans kvalitet

Framtagna metoder i projektet begränsas i viss mån av datans kvalitet, och framför allt samplingsfrekvens. Det är möjligt att ta stora kliv i utvecklingen av analys utifrån tillhandahållen data, vilket påvisats av projektets resultat, men för framtiden och fortsatt utveckling av avancerad och precis analys hade det varit fördelaktigt med tillgång till mer högupplöst data.

Att få ihop ett tillräckligt stort dataset av hög kvalitet var en utmaning under projektet. Trots att många störningar fanns registrerade så saknades ibland vågformen, vilket krävdes för analysen. Dessutom försvårades arbetet något av att nuvarande klassificering av och riktning på störningar ibland visade sig vara felaktiga. Vilket innebar ytterligare arbete med manuell annotering för att säkerställa en stabil datagrund innan applicering av ML kunde göras.

8.2 MÖJLIGHETER OCH FRAMTIDENS SMARTA ELNÄT

Det här avsnittet inleds med att diskutera möjligheterna med den datadrivna analys som är tekniskt möjlig idag. Vidare resoneras kring de möjligheter som kan uppkomma i framtidens smarta elnät, och lyfter specifikt upp högre samplingsfrekvens och lokal analys "on the edge", som två möjliggörare.

8.2.1 Kommunikation, beräkningskraft och datahantering

All data som använts inom ramen för detta projekt kommer från befintliga PQ-mätare. Det finns en rad olika typer av PQ-mätare på marknaden. Som bevisats i detta projekt är det möjligt att genomföra ML-baserad analys med befintliga produkter.

Uppkopplingsmässigt har de flesta PQ-mätare ethernet eller wifi, och i vissa mer sällsynta fall finns PLC (power line communication), vilket är en ännu snabbare kommunikationsfunktion. Befintlig infrastruktur för uppkoppling finns alltså redan på plats för att initiera nya digitala datadrivna lösningar. Det kan dock kräva viss översyn och konfiguration för att säkerställa att den fulla potentialen utnyttjas. Dessutom kan ytterligare komprimeringsmetoder av data utöka möjligheterna med dagens kommunikation.

Flera av dagens PQ-mätare har tillräcklig beräkningskraft för att använda ML-metoder likt de som presenterats i detta projekt. FPGA (Field-Programmable Gate Array) och DSP (Digital signal processing) är två exempel på kretsar som är kompatibla med de ML-metoder som presenterats i projektet. Det är alltså, med

befintlig infrastruktur, möjligt att implementera AI-lösningar. I takt med att priset på beräkningskraft sjunker [26], finns det också goda möjligheter att utöka befintlig beräkningskraft, genom exempelvis GPU:er, för att möjliggöra ännu mer avancerade och precisa beräkningar både lokalt och centralt.

Dagens PQ-mätare har begränsade möjligheter till datalagring och att genomföra lokala ML-beräkningar "on the edge". Oftast utgörs befintlig lagring av RAM-minne som endast sparar data temporärt för att sedan skicka vidare till högre instans. I mer sällsynta fall finns SSD-hårddiskar tillgängliga för något mer extensiv lagring. De lokala lagringsmöjligheter mätarna har begränsar därmed valet kring mängden data som kan och bör överföras.

Sammanfattningsvis är det idag möjligt för användaren att skicka, hantera och lagra data kontinuerligt eller i delar med den infrastruktur som redan finns på plats. Samtidigt finns det mer avancerad teknik tillgänglig till ett sjunkande pris, vilket kan möjliggöra lokala "on the edge"-beräkningar samt bättre prestanda, hastighet, noggrannhet och djup av de AI-lösningar som appliceras.

8.2.2 Mätning och analys av en högre samplingsfrekvens

Att mäta med en högre samplingsfrekvens och därmed spara mer högupplöst data kommer med flera fördelar. Till att börja med skulle det innebära goda förutsättningar för en fortsatt utvidgad grundorsaksanalys avseende fler underliggande fel till spänningsdippar och transienter. Vidare skulle en sådan samplingsfrekvens vara fördelaktig för prediktering av energiförbrukning, särskilt om man vill titta över en längre tidshorisont. Dessutom skulle en mer djupgående analys av andra typer av störningar vara möjlig, där en tillräckligt hög frekvens synliggör grundorsaken för andra mer komplexa störningar. Till sist blir samplingsfrekvensen viktig vid identifiering av riktning för PQ-störningar. Det går, som påvisats i projektet, att ge indikationer om riktningen även vid en lägre samplingsfrekvens. Men för en viss typ av störningar, såsom transienter, kan man med nuvarande samplingsfrekvens inte säga något om riktningen.

Det här tillvägagångssättet är fördelaktig ur ett analysperspektiv, och kan ge mycket information som idag är okänd, men kan också innebära vissa praktiska implikationer. Exempelvis kan den här typen av mätning medföra kommunikations- och lagringsproblematik. Kring detta resoneras det fortsatt i nästa stycke.

8.2.3 Analys "on-the-edge"

Analys "on-the-edge" innebär att behandla data lokalt i algoritmer lagrade på hårdvara nära sensorn istället för i algoritmer i molnet, vilket annars är vanligt för ML och övrig dataanalys.

En framtida approach till detta kan vara att all PQ-data som samlas in lokalt inte skickas i realtid för datalagring vid en högre instans. Att istället fortsatt utveckla analys som dels kan utföras lokalt och dels centralt, kan komma möjliggöra att PQ-mätare bättre kan samla in, komprimera och lagra data lokalt endast för de mest relevanta funktionerna och på så sätt möjliggöra en optimerad hantering vid högre instans. Samtidigt kan realtidsdata begränsas till de mest kritiska punkterna i nätet

samt anpassas med förutbestämda kriterier som utvärderas efter behov för att möta exempelvis den kvalitet som krävs för önskad AI-analys. Ett annat alternativ är att realtidsdata kan efterfrågas till högre instans som komplement vid specifik PQ-analys, till exempel när en större händelse skett. Genom att utföra analys närmare mätningen, det vill säga "on the edge", antingen delvis eller helt, minskar beräkning och kommunikationstiden och möjliggör till exempel att endast överföra relevant information. Ambitionen är att en sådan approach skulle kunna möjliggöra bland annat mätning till en högre samplingsfrekvens, utan bandbredds- och lagringsproblematik.

Tabell 11 bygger på NASPI (2020) resonemang och visar olika möjliga upplägg för att strukturera framtida datainsamling och analys [27]. Detta för att konkretisera hur nätägare kan behöva göra framtida avvägningar vid uppbyggnad av en smartare infrastruktur för data och analys. Det finns exempelvis PQ-störningar, där det kan vara till fördel att utföra analysen lokalt och i realtid (till exempel frekvensinstabilitet), för att därmed möjliggöra korrigering för den typen av avvikelser. Samtidigt kan detta också utföras offline och i efterhand, likt nuvarande PQ-analys, men då med en naturlig fördröjning. Därmed kan frågan ställas ifall viss grundorsaksidentifiering ska ske lokalt för att endast skicka de mest kritiska PQ-störningarna upp till högre instans, för att på så vis minimera nödvändig bandbredd, vilket kan komma att bli en framtida flaskhals.

Tabell 11: Olika typer av analyser och hur de kan utföras i relation till plats och tid

Plats för analys och åtgärd		
Tid för analys	Lokalt - "on the edge"	Centraliserat - kontrollrum
Realtid (sekunder eller minuter)	- Referenssignaler för kompensation av PQ-störningar (t.ex. frekvensinstabilitet eller övertoner) - Detektion av allvarliga fel av hårdvara - Överblick av tillstånd för matning	- Förutspå laster - Situationsmedvetenhet på hög nivå - Samordnade larm och varningar
I efterhand eller offline (minuter eller timmar)	- Tillståndskontroll - Karaktärisering av distribuerad generation - Analys av PQ-störningar (för val av data att skicka till högre instans) - Detektion av partiella urladdningar	- Analys av grundorsaker för PQ-störningar - Detektion och analys för partiella urladdningar - Överblick och analys av laster - Förutspå laster - Uppdatering av datadrivna metoder - Validering av modeller

Tack vare utvecklingen av datalagring i fält och moln, snabbare nätverk för kommunikation, och flera andra verktyg för datahantering öppnar sig möjligheten att förvara, samla in och hantera väldigt stora mängder data mer effektivt och till ett lägre pris. Detta kommer i framtiden innebära ytterligare möjligheter till att kontinuerligt förbättra både frekvens och mängden datapunkter som kan samlas in. I och med detta blir nästa fråga ifall analys ska utföras lokalt "on the edge" eller centralt i exempelvis kontrollrummet hos nätägare. Förmodligen kommer detta inte vara en fråga om antingen eller, snarare kommer nätägare behöva finna en balans som optimerar olika typer av analys och de kostnader som är relaterade därtill. I och med denna rapport hoppas värdet av datadrivna metoder och intelligent analys framgå, och därmed behovet av att investera ytterligare i nämnda områden för att på så vis möjliggöra fortsatt utveckling.

9 Slutsatser

I det här projektet har Eneryield applicerat egenutvecklade ML-metoder för klassificering, grundorsaksidentifiering och riktningsidentifiering av PQ-händelser med gott resultat. Även prediktering av energiförbrukning har utförts med hög träffsäkerhet. Vidare har en behovsverifiering genomförts tillsammans med projektets deltagare. Av detta framkom att det är på tillgänglig data möjligt att göra en mer djupgående analys, samt att det finns ett uttryckt behov från nätägare för detta. En grundorsaksidentifiering av spänningsdippar lyftes fram som extra intressant och värdeskapande. En sådan typ av analys kan automatisera processer som idag är manuella och tidskrävande samt tillhandahålla en mer djupgående förståelse av elnäts generella hälsa. Dessutom möjliggörs en tydligare ansvarsfördelning och skuldfråga för störningar.

För att åskådliggöra det värde som en ML-baserad PQ-analys kan skapa, har en exempelrapport i PDF-format utformats. I rapporten som genereras automatiskt kan användare se vilken underliggande orsak respektive PQ-störning har. PDF-rapporten är ett första steg men för ökad användarvänlighet belyses integration i existerande mjukvara eller ett extern API, för att tillgängliggöra resultatet av de nya analysmetoderna, som relevanta framtida steg.

Som det framgår av projektets resultat så är redan viss typ av djupgående analys möjlig, men insamling och export av data saknar idag standardiserade metoder. Ett uniformt tillvägagångssätt för detta krävs för att möjliggöra framtida externa analysmetoder på ett funktionellt sätt. Dessutom är datan som samlats in relativt lågupplöst, och framtida analys skulle gynnas av en högre samplingsfrekvens. En möjliggörare för detta kan vara att genomföra analys "on the edge", med fördelen att mäta till en högre samplingsfrekvens samtidigt som man kringgår eventuell lagrings-, beräkning- och kommunikationsproblematik.

10 Fortsatt arbete

I projektet har Eneyield uppnått goda resultat beträffande identifiering av riktning, klassificering och grundorsaksidentifiering av PQ-störningar. Dessa kan dock fortsatt förbättras, och skulle gynnas av mer data. Ytterligare data skulle kunna bidra till att höja träffsäkerheten, samt algoritmernas förmåga att generalisera över olika nät, vilket är relevant då Eneyield strävar efter att utveckla en så precis och generell metod som möjligt.

Fortsatt arbete fokuserar också mot att bredda grundorsaksanalysen ytterligare. Analysen skulle kunna utvidgas med fler möjliga typer av underliggande orsaker, detta då nuvarande analys har begränsats av de grundorsaker man har sett ur tillhandahållen data. Ett mer diversifierat dataset med andra typer av orsaker skulle förbättra slutresultatet, och därmed skapa ytterligare värde för slutanvändaren. Detta skulle kunna utvecklas relativt snabbt, genom nära samarbete med nätägare och ett dataset innehållande PQ-störningar där grundorsaken är känd från utförlig manuell analys.

Beträffande metoden för identifiering av riktning, så är förhoppningen att träffsäkerheten kan höjas ytterligare. Vad som behöver göras då, men som inte funnits utrymme för i projektet, är att undersöka vad de felaktigt identifierade störningar beror på. Algoritmen i sig kan utvecklas, men det finns också en möjlighet att den ursprungliga identifieringen av riktningen kan vara felaktig utförd vilket då påverkar resultatet, eftersom algoritmen är tränad på den ursprungliga annoteringen. Att vidare undersöka, kvalitetssäkra och utvidga data för träning föreslås därmed som fortsatt arbete.

På en högre nivå och ur ett mer långsiktigt perspektiv är rekommendationen att fokusera kring att förflytta analysen *on-the-edge*, och mäta till en högre samplingsfrekvens. Tillgång till detta skulle förmodligen förbättra nuvarande analys avsevärt, samtidigt som bandbredds- och lagringsproblematiken kringgås.


Nuvarande metoder begränsas dessutom i viss mån med avsaknaden av standardiserad metod för export av data och med tillhörande uniformt dataformat. För att effektivt tillhandahålla stora dataset krävs därmed framtagandet av en standardiserad metod för export av data, med tillhörande gemensamt format. En sådan metod skulle gynna utveckling för analys av PQ, och därmed möjliggöra data-drivna metoder i en mycket större skala än vad som idag är möjligt.



11 Referenser

- [1] CIRED. 2018. Power Quality and EMC Issues with Future Electricity Networks.
<http://cired.net/uploads/default/files/final-report-C4.24-CIRED.pdf> (Hämtad: 2020-06-09)
- [2] IVA. 2016. Sveriges framtida elnät.
<https://www.iva.se/globalassets/rapporter/vagval-energi/vagvael-sveriges-framtida-elnat-b.pdf> (Hämtad: 2020-06-09)
- [3] Balouji, E. & Bäckström, K. 2019. *Deep Learning Based Harmonics and Interharmonics Pre-Detection Designed for Compensating Significantly Time-varying EAF Currents*. IEEE Industry Applications Society Annual Meeting.
- [4] Balouji, E., Yu-Hua Gu, I., Bollen, M., Bagheri, A. & Nazari, A. 2018. *A LSTM-based Deep Learning Method with Application to Voltage Dip Classification*. 18th International Conference on Harmonics and Quality of Power (ICHQP).
- [5] Balouji, E. & Salor, O. *Classification of Power Quality Events Using Deep Learning on Event Images*. 3rd International Conference on Pattern Recognition and Image Analysis (IPRIA)
- [6] Ne.se. 2020. *Artificiell Intelligens - Uppslagsverk - NE.Se*.
<https://www.ne.se/uppslagsverk/encyklopedi/enkel/artificiell-intelligens> (Hämtad: 2020-06-09)
- [7] Elements of AI. 2020. *Grunderna i AI*. Linköping Universitet, Tekniska fakulteten, 581 83 Linköping.
- [8] MonkeyLearn. 2019. *An Introduction to Machine Learning*.
<https://monkeylearn.com/machine-learning/> (Hämtad: 2020-07-09)
- [9] Guru99. 2020. *Supervised vs Unsupervised Learning: Key Differences*.
<https://www.guru99.com/supervised-vs-unsupervised-learning.html> (Hämtad: 2020-07-09)
- [10] Bollen, M. & Yu-Hua Gu, I. 2006. *Signal Processing of Power Quality Disturbances*. New Jersey: John Wiley & Sons, Inc
- [11] Olguin, G. 2005. *Voltage Dip (Sag) Estimation in Power Systems based on Stochastic Assessment and Optimal Monitoring*. Diss., Chalmers University of Technology.
<http://publications.lib.chalmers.se/records/fulltext/5617/5617.pdf>
- [12] Burgos, P. B. & Wiechmann, E. P. 2005. *Extended Voltage Swell Ride-Through Capability for PWM Voltage-Source Rectifiers*. IEEE Transactions on Industrial Electronics 52 (4): 1089 - 1098.
- [13] Bollen, M. 2000. *Understanding Power Quality Problems: Voltage Sags and Interruptions*. Wiley-IEEE Press.
- [14] Ortmeyer, T., Reeves, J., Hou, D. Member & McGrath, P. 2010. *Evaluation of Sustained and Momentary Interruption Impacts in Reliability-Based Distribution System Design*. IEEE Transactions on Power Delivery 25 (4).

- [15] Cividino, L. 1992. Power factor, harmonic distortion; causes, effects and considerations. Fourteenth International Telecommunications Energy Conference - INTELEC '92
- [16] Bollen, M., Styvaktakis, E. & Yu-Hua Gu, I. 2005. *Categorization and Analysis of Power System Transients*. IEEE Transactions on Power Delivery 20 (3): 2298 - 2306.
- [17] Renner, H. & Sakulin, M. 2000. *Flicker propagation in meshed high voltage networks*. Ninth International Conference on Harmonics and Quality of Power. Proceedings
- [18] Ferdous, J. Arafat, Y. & Azam, A. 2013. *Flicker level mitigation of weak grid connected wind turbine with DFIG by injecting optimum reactive power using STATCOM*. International Conference on Informatics, Electronics and Vision (ICIEV)
- [19] Bhattacharyya, S. & Cobben, S. 2011. *Consequences of Poor Power Quality – An Overview*.
- [20] Cobben, J.F.G., Cuk, V., & Kling, W.L. 2011. *Increasing energy efficiency by improving power quality*. Proceedings of the 15th WSEAS international conference on Systems
- [21] Muhamad, M. I. & Radzi, M. 2008. *The Effects of Power Quality to the Industries*. 5th Student Conference on Research and Development, SCORED
- [22] ElShennawy, T. I., El-Gammal M. A. & Abou-Ghazala A. Y. 2009. *Voltage Sag Effects on the Process Continuity of a Refinery with Induction Motors Loads*. American Journal of Applied Sciences 6 (8): 1626-1632.
- [23] Kumar, L. A. & Alexander, S. A. 2019. *Computational Paradigm Techniques for Enhancing Electric Power Quality*. 1st edition. New York: CRC Press.
- [24] Liang, X. 2017. *Emerging Power Quality Challenges Due to Integration of Renewable Energy Sources*. IEEE Transactions on Industry Applications 53 (2): 855 - 866.
- [25] Sahoo, S. & Bollen, M. 2019. *Elkvalitetsarbete i Sverige 2019*. Energiforsk rapport, 2019:633.
- [26] The Hamilton Project. 2020. One dollar's worth of computer power has grown significantly since the 1980s.
https://www.hamiltonproject.org/charts/one_dollars_worth_of_computer_power_1980_2010 (Hämtad: 2020-07-15)
- [27] NASPI. 2020. High-resolution, Time-synchronized Grid Monitoring Devices.

Bilaga A: Exemplifiering av analys

Vågform	Ursprunglig klassificering	Energylös analys
	Transient	Klassificering: Spänningsdipp Grundorsak: Transformer energization
	Avbrott	Klassificering: <i>Non-fault</i> avbrott Grundorsak: Roterande maskin

	Spänningsdipp	Klassificering: Spänningsdipp Grundorsak: <i>Autoreclosure</i> i distributions- ledare
	Transient	Klassificering: Spänningsdipp Grundorsak: Transformer saturation

Bilaga B: PQ-rapport

Machine learning based power quality analytics





**Classification, root-cause and direction
identification of power quality events**

ENERYIELD



Table of contents

VOLTAGE DIPS	3
TRANSIENTS	4
INTERRUPTIONS	5
EARTH FAULTS	6



Voltage dips

Date & time	Root-cause	Direction	Event figure
2020-01-05 18:45	Transformer energization	Upstream	 A line graph showing three-phase voltage (V) over time (samples). The voltage is stable at approximately 100V until sample 500, where it drops sharply to about 20V for a duration of approximately 100 samples before recovering to the original level. The y-axis ranges from -5 to 5, and the x-axis ranges from 0 to 3000.
2020-01-07 16:14	Three phase fault in distribution system. Followed by transformer saturation	Upstream	 A line graph showing three-phase voltage (V) over time (samples). The voltage is stable at approximately 100V until sample 500, where it drops to zero for about 100 samples. After recovery, the voltage amplitude is significantly reduced, indicating transformer saturation. The y-axis ranges from -5 to 5, and the x-axis ranges from 0 to 3000.
2020-01-13 01:11	Autoreclosure in distribution feeder	Upstream	 A line graph showing three-phase voltage (V) over time (samples). The voltage is stable at approximately 100V until sample 500, where it drops to zero for about 100 samples. After recovery, the voltage amplitude is significantly reduced, indicating transformer saturation. The y-axis ranges from -5 to 5, and the x-axis ranges from 0 to 3000.
2020-01-24 07:23	Transformer saturation	Downstream	 A line graph showing three-phase voltage (V) over time (samples). The voltage is stable at approximately 100V until sample 500, where it drops to about 20V for a duration of approximately 100 samples before recovering to the original level. The y-axis ranges from -5 to 5, and the x-axis ranges from 0 to 3000.




Transients

Date & time	Root-cause	Direction	Event figure
2020-01-03 07:29	Capacitor energization	Upstream	
2020-01-07 12:14	Capacitor deenergization	Upstream	

Interruptions

Date & time	Root-cause	Event figure
2020-01-01 09:29	Motor start and ending	
2020-01-07 09:11	Rotating machinery	

Earth faults

Date & time	Type	Root-cause	Event figure
2020-01-22 22:29	Intermittent	Aging cable	
2020-01-25 21:14	Solid	Weather condition and insulator	
2020-01-27 14:14	Low ohmic	Removal of large load	

Sökord

Artificiell intelligens, maskininläring, djupinläring, elkvalitet, smarta elnät, digitalisering, grundorsaksidentifiering

MASKININLÄRNING, ELKVALITET OCH SMARTA ELNÄT

När samhället elektrifieras i högre grad och elnätet förändras genom nya kraftkällor och olika typer av laster, uppstår nya utmaningar. En viktig komponent att ta hänsyn till är elkvalitet som i dagsläget övervakas och analyseras av nätägaren. Genom artificiell intelligens kan man göra en fördjupad analys av den elkvalitetsdata som samlas in, vilket skapar nya möjligheter att åtgärda störningar.

Att identifiera grundorsak till spänningsdippar är värdefullt och kan automatisera processer som idag görs manuellt vilket är tidskrävande. Det innebär också en djupare förståelse av elnäts generella hälsa och förtydligar ansvarsfördelning och skuldfråga i samband med störningar.

Resultaten visar att framtidens smarta digitala elnät skulle gynnas av att mäta till en högre samplingsfrekvens, för att ännu bättre förstå olika störningars ursprung och inverkan. Man skulle till exempel kunna genomföra analys "on the edge", då man i större utsträckning kan kringgå eventuella lagrings-, beräkning- och kommunikationsproblem.

Ett nytt steg i energiforskningen

Energiforsk är en forsknings- och kunskapsorganisation som samlar stora delar av svensk forskning och utveckling om energi. Målet är att öka effektivitet och nyttiggörande av resultat inför framtida utmaningar inom energiområdet. Vi verkar inom ett antal forskningsområden, och tar fram kunskap om resurseffektiv energi i ett helhetsperspektiv – från källan, via omvandling och överföring till användning av energin. www.energiforsk.se



Energiforsk