



CHALMERS

**Undersökning av havsvågors korrelation till
mikroseismikens effektspektrum genom artificiella
neurala nätverk**

KANDIDATARBETE VID INSTITUTIONEN FÖR RYMD- OCH GEOVETENSKAP

RRYX02-14-05

Författare:

Erik Hellsten

Emilio Jorge

Markus Polleryd

David Svensson

Handledare:

Hans-Georg Scherneck

Datum: 19 maj 2014

Sammanfattning

Överallt på jorden kan svaga vibrationer kallade mikroseismik uppmätas. Idag är det känt att mikroseismik huvudsakligen uppkommer från vågor på haven. Sambandet mellan uppmätta vibrationer och vågor har dock ännu inte bestämts exakt. I detta arbete har vi undersökt samband mellan havsvågors höjd och frekvensfördelning i mikroseismiken genom artificiella neurala nätverk. Vi har använt oss av ett neuralt nätverk som tränats mot data med syftet att skapa en modell över sambandet. Resultaten pekar på att det är möjligt att använda neurala nätverk för att modellera mikroseismik utgående från information av havsvågor. För en mer korrekt fungerande modell krävs dock att man tar hänsyn till fler faktorer än enbart vågornas höjd och mikroseismikens frekvensfördelning. De förutsägelser om mikroseismik simulerade av det skapade neurala nätverket antyder att större delen av mikroseismiken uppmätt i Onsala härstammar från Europas kust, framför allt Norska havet och Biscayabukten.

Abstract

Microseismic activity are vibrations that originate mainly from waves at sea, but the exact nature of this correlation is complicated and still unknown. In this report we have tried to correlate the frequency distribution of the microseisms with wave heights at sea by utilizing an artificial neural network. Our results show that this seems to be a good approach although more parameters than just microseismic frequency distribution and wave height need to be included to obtain more exact simulations of microseismic frequency distribution from wave height data. The simulations created by our neural network show that the greater part of microseismic activity measured in Onsala originates from the European coast, above all from the Norwegian Sea and the Bay of Biscay.

Tilkännagivanden

Vi vill tacka Hans-Georg Scherneck för hans outtröttliga engagemang, visdom och vilja att hjälpa oavsett tid på dygnet. Utan hans hjälp hade vi aldrig nått så långt som vi gjorde.

Erik Hellsten, Emilio Jorge, Markus Polleryd och David Svensson

Innehåll

1	Inledning	1
1.1	Syfte	1
1.2	Övergripande tillvägagångssätt	2
1.3	Avgränsningar	2
2	Teoretiskt ramverk	3
2.1	Mikroseismik	3
2.1.1	Teoretisk härledning av modell för mikroseismik	3
2.1.2	Experimentella studier av mikroseismik	6
2.2	Mätning av mikroseismik	7
2.3	Matematisk beskrivning av effektspektrum	8
2.4	Artificiella neurala nätverk	9
3	Verkställande av korrelationsmodell	14
3.1	Förbehandling av gravimeterdata	14
3.2	Konstruktion av effektspektrum från gravimeterdata	16
3.3	Förbehandling av vågdata	18
3.4	Korrelation genom artificiella neurala nätverk	19
3.4.1	Val av antal neuroner i det gömda lagret	21
3.4.2	Analys med hjälp av det tränade nätverket	22
3.5	Realisering av det artificiella neurala nätverket	24
4	Resultat	25
4.1	Träning- och generaliseringsfel vid optimering av neuronantal	25
4.2	Prestandan hos det artificiella neurala nätverket	27
4.3	Frekvenstest med det artificiella neurala nätverket	30
4.4	Karta över mikroseismikgeneration på Atlanten	42
5	Diskussion	43
5.1	Antal neuroner och iterationer	43
5.2	Samband mellan våghöjd och mikroseismik	43
5.3	Felkällor	45
5.3.1	Neurala nätverket	45
5.3.2	Effektspektrum	46
5.3.3	Hantering av vågdata	46
5.4	Fortsatta studier	47
6	Slutsats	48

1 Inledning

Vibrationer i jordskorpan har länge intresserat människan och mycket forskning har bedrivits inom ämnet. Redan så tidigt som 132 e. Kr. tillverkade Zhang Heng[1] det första kända seismoskopet för detektering av jordskalv. Sedan dess har utrustningen blivit allt känsligare och omkring år 1850 gjordes första observationen att jorden vibrerar konstant med väldigt låg amplitud [2]. De flesta seismologer förkastade dessa vibrationer som brus medan andra försökte förklara dess ursprung. Idag är det känt att den huvudsakliga orsaken till dess uppkomst är vågor på haven och dessa svaga oscillationer har tilldelats namnet mikroseismik. Än idag är mikroseismik ett förhållandevis litet forskningsområde. De flesta teorier som förklarar hur mikroseismik genereras bygger på en artikel av M.S. Longuet-Higgins som gavs ut år 1950 och heter *A theory about the origin of Microseisms* [3]. Året därpå verifierade Cooper och Longuet-Higgins delar av teorin med experimentell data [4]. De senaste decennierna har teorin dock tagit fart och teorin kring mikroseismiken utvecklas kontinuerligt parallellt med att tillämpningar hittas.

Det mest konkreta exemplet på tillämpning av mikroseismik är att använda sig av dess effektspektrum för att göra en uppskattning av vädret på haven. Att implementera en modell som gör denna uppskattning kan tyckas enkelt då mikroseismikens amplitud kan vara 40 gånger större en dag då det är storm jämfört med en lugn dag. Dessvärre har inte någon studie lyckats göra exakta förutsägelser om hur vågor på haven påverkar uppmätt mikroseismik. Svårigheten ligger bland annat i att de processer som generar mikroseismik inte är linjära [3] och är dessutom väldigt känsliga för hur djupt [5] havet är och vilken relativ riktning [3] vågorna har.

Flertalet olika metoder har använts med syfte att försöka prognostisera havsvågors påverkan på uppmätt mikroseismik och påvisa tidigare teorier. Bland de mindre utforskade metoder som tillämpats kring mikroseismik är artificiella neurala nätverk (ANN). Genom tillgång till stora mängder historisk data från havsvågor och mikroseismik under samma tidsperioder, kan ANN lära sig sambanden mellan dessa. På grund av dess förmåga att hitta icke-linjära samband skulle ANN kunna vara en metod med stor potential att förutsäga havsvågors påverkan på mikroseismik. Detta innebär att det skulle kunna vara möjligt att studera hur vågorna i olika områden påverkar mikroseismiken genom att skapa vågdata med vågor i dessa områden och se hur deras simulerade mikroseismik skulle se ut.

1.1 Syfte

Arbetet syftar till att undersöka möjligheten att använda artificiella neurala nätverk till att finna korrelationer mellan havsvågor på Atlanten och uppmätt förändring av tyngdaccelerationen vid gravimetern på Onsala rymdobservatorium. I fallet av att korrelationer finnes ska dessa studeras och relateras till tidigare teori inom området mikroseismik.

1.2 Övergripande tillvägagångssätt

Vi valde att jämföra mikroseismikens frekvens med våghöjd på olika delar av Atlanten. Detta sambandet är tillräckligt komplext för att någon form av enklare regression inte skulle kunna beskriva sambandet i tillräckligt hög utsträckning. Vi valde därför att använda oss av ett artificiellt neuralt nätverk för att hitta korrelationen. För att studera frekvensen av gravimetersignalen konstruerade vi effektspektrum vilket beskriver energitätheten för en process som funktion av frekvens. Vi använde sedan effektspektrumet som indata till det neurala nätverket. På följande länk återfinns all kod för programmet: <https://github.com/Kandidatarbete-RRYX02-14-05/Huvudprogram>. I den senare delen av projektet ägnade vi mer tid till att testa hur olika parametrar i det neurala nätverket påverkade resultatet. Vi tolkade resultaten och relaterade dem till tidigare studier inom mikroseismik.

1.3 Avgränsningar

Teorin bakom mikroseismik är fortfarande relativt outforskad och det finns många parametrar vilkas inverkan på mikroseismiken är oklar. Vi har studerat och tagit hänsyn till de parametrar vi tror ha störst inverkan enligt den teori som finns. Dock återstår många faktorer vilka hade varit intressanta att studera om vi hade utvidgat projektet. Vi har valt att avgränsa oss till att studera korrelationen mellan våghöjden på olika geografiska platser och effektspektrumet av tyngdaccelerationen. Havsvågornas riktning och frekvens är två potentiellt påverkande faktorer som vi inte behandlar. Anledningen är att hålla problemet på en grundläggande nivå då användning av artificiella neurala nätverk inom mikroseismik är relativt outforskad.

Vi har valt att endast använda framåtmatande neurala nätverk eftersom det är den främst använda typen. Vidare skapar vi nätverk med endast ett dolt lager, även här för att hålla problemet på en grundläggande nivå samt att det är mer än adekvat i nästan samtliga tillämpningar [6].

Till sist avgränsade vi oss geografiskt till norra Atlanten, från USA:s östkust till Spaniens västkust; mer specifikt studerar vi det området som ligger mellan longituderna $W70^\circ$ och $E15^\circ$ samt latituderna $N35^\circ$ och $N70^\circ$. Den främsta anledningen till att begränsa arbetsområdet är att mikroseismik avtar med det horisontella avståndet från ursprunget vilket endast gör det intressant att kolla på områden relativt nära mätinstrumentet. Storleksordningen på det valda området har baserats på tidigare experiment av bland annat Kedar [7]. En fördel med att avgränsa området är att det minskar storleken på indatan till det neurala nätverket vilket har som konsekvens att det neurala nätverket lättare tränas.

2 Teoretiskt ramverk

Avsnittet syftar till att förse läsaren med en nödvändig teoretisk bas inför senare resultat och diskussion. Ämnen som behandlas är mikroseismikens uppkomst från kustnära och kolliderande vågtåg, strukturen av ett framåtmåtande neuralt nätverk samt effektspektrum.

2.1 Mikroseismik

Historiskt sett har den önskade signalen vid seismologiska mätningar varit vibrationer från jordbävningar. Men som vid alla fysikaliska mätningar uppstår det alltid, utöver den sökta signalen, brus. En av de vanligaste typerna av uppmätt brus vid seismiska mätningar är så kallat seismiskt bakgrundsbrus. Detta bakgrundsbrus kan detekteras över hela jorden även om lokal inverkan från till exempel trafik och väder exkluderas. Sedan andra hälften av 1800-talet [2] då seismometrar blev känsliga nog att mäta det seismiska bakgrundsbruset har det försökts isoleras och förklaras.

Det var först i sin banbrytande artikel *A Theory of the Origin of Microseisms* som Longuet-Higgins presenterade sin teori. Den stora skillnaden var att han använde sig av andra ordningens approximation av tryckvågor i vatten för att beräkna tryckvariationer på havsbotten istället för första ordningens approximation som hade gjorts tidigare [3]. Genom detta visade han att stående havsvågor ger upphov till tryckvågor som inte avtar med djupet. Teorins främsta förutsägelse var att dessa tryckvågor borde ha dubbelt så hög frekvens som havsvågorna vilket överensstämmer med experimentell data.

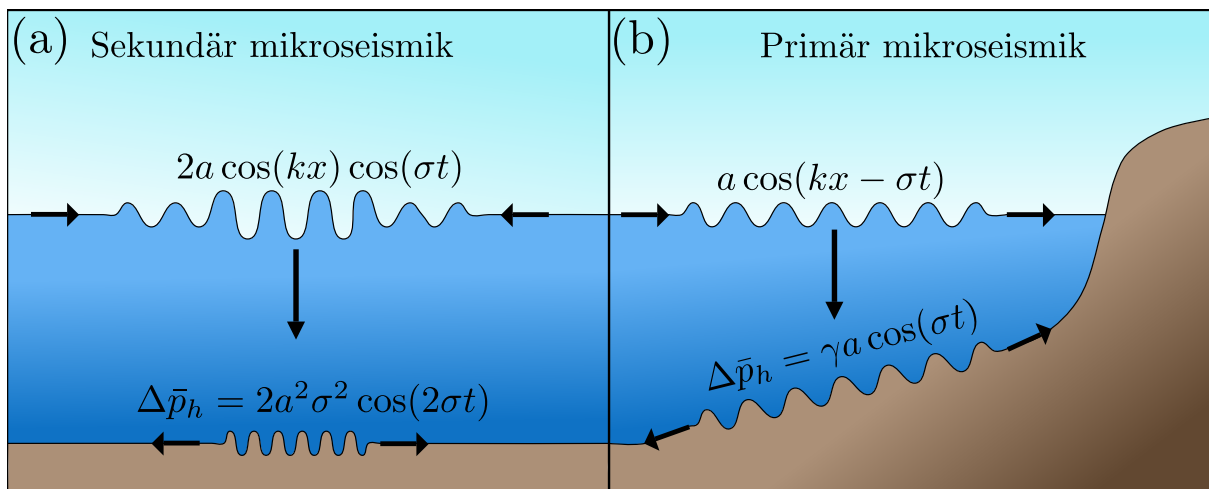
Idag definieras vanligtvis mikroseismik som seismiskt brus med frekvenser mellan 30 mHz och 1 Hz [8] som skapats av naturliga orsaker. Ofta delas bruset upp i en grupp som har samma frekvens som havsvågorna, vilken kallas primär mikroseismik (PM), och en grupp med dubbla havsvågsfrekvensen, vilken går under namnet sekundär mikroseismik (DF¹). Uppdelningen är central i tolkningen av data då primär och sekundär mikroseismik bygger på två olika mekanismer, se figur 1.

2.1.1 Teoretisk härledning av modell för mikroseismik

Mikroseismik är ännu relativt outforskat och det är i nuläget ingen som vet till vilken grad olika faktorer bidrar. Den teori som finns idag grundas till stor del på Longuet-Higgins *A Theory of the Origin of Microseisms* [3]. Longuet-Higgins utgår ifrån hur vågor i motsatt riktning ger upphov till tryckvågor i vertikal led som inte avtar med djupet. Han modellerar sedan hur vibrationer i havsbotten uppstår av dessa tryckvågor.

Longuet-Higgins börjar sitt resonemang med antagandet att vattnet är inkompressibelt och att rörelseekvationerna i vattnet är konservativa. Dessa antagandes innebär att

¹Från Double Frequency microseisms



Figur 1: Illustration över mikroseismikens uppkomst. (a) beskriver sekundär mikroseismik och (b) beskriver primär mikroseismik. I illustration (a) rör sig två vågtåg med amplitud a och frekvens σ i motsatt riktning vilket ger upphov till en stående våg med frekvensen σ . Den stående vågen kommer att skapa tryckvågor som propagerar ner i vattnet. Medeltrycket $\Delta \bar{p}_h$ på en punkt under den stående vågen kommer att varieras med dubbelt så hög frekvens som den stående vågen. Detta innebär att även den mikroseismik som genereras av tryckskillnaden kommer att ha dubbelt så hög frekvens som den stående vågen. Illustration (b) visar hur ett vågtåg med amplituden a och frekvensen σ rör sig mot en kust. Eftersom att vattnet blir förhållandevis grunt kan vågtåget transmitta nog med energi för att generera mikroseismik. Då vågorna verkar direkt på botten kommer den genererade mikroseismiken att ha samma frekvens som vågtåget.

det går att bilda en skalärpotential Φ för rörelsen sådan att $\nabla \times \Phi = 0$. Han antar dessutom att vattenvågorna är periodiska i x-led med en våglängd λ . Med dessa antaganden tecknar han Bernoulliekvationen i två dimensioner (x och z) enligt följande:

$$\frac{p - p_s}{\rho} - gz = \frac{\partial \Phi}{\partial t} - \frac{1}{2}(w^2 + u^2) + \theta(t). \quad (1)$$

Här är p trycket vid djupet z , ρ är vattnets densitet, g är tyngdaccelerationen och p_s är trycket på ytan vilket antas vara konstant. Vidare är $w = -\frac{\partial z}{\partial t}$, $u = -\frac{\partial x}{\partial t}$ och θ en godtycklig funktion av t . Eftersom Φ är en harmonisk funktion², periodisk i x-led och begränsad i z-led, för $z > 0$, kan det enligt Longuet-Higgins visas att Φ måste avta med djupet minst lika snabbt som $\exp(-2\pi z/\lambda)$. Detta medför att för stora z relativt λ är

$$\Phi \approx w \approx u \approx 0,$$

och bernoulliekvationen ovan (1), reduceras till

$$\frac{p - p_s}{\rho} - gz = \theta(t). \quad (2)$$

Utifrån detta visar han sedan att medeltrycket på botten på djupet h är noll i fallet av en progressiv våg men att det i fallet med två motriktade vågtåg³ med samma frekvens och amplituderna a_1 och a_2 beskrivs med följande ekvation:

$$\frac{\bar{p}_h - p_s}{\rho} - gh = -2a_1 a_2 \sigma^2 \cos(2\sigma t), \quad (3)$$

där \bar{p}_h är medeltrycket på djupet h , $\sigma = \frac{2\pi}{T}$ och T är havsvågornas periodtid. Det kan visas att om vågtågens riktning avviker mer än 10° från att läget där vågtågen är helt motriktade minskar uppkomsten av andra ordningens tryckvariationer markant [9].

Vidare ifall $a_1 = a_2$ bildar vågorna tillsammans en stående våg med amplitud $a = 2a_1$. Ekvation (3) blir i så fall

$$\frac{\bar{p}_h - p_s}{\rho} - gh = -\frac{1}{2}a^2 \sigma^2 \cos(2\sigma t). \quad (4)$$

Vidare fortsätter Longuet-Higgins sin härledning med att undersöka tryckvariationerna utan att längre göra antagandet om havsvattnets inkompressibilitet. Han visar att om havsdjupet är omkring halva havsvågornas våglängd så är kompressibiliteten försumbar och ekvationerna (3) och (4) förblir applicerbara. Om djupet däremot är i samma

²Att en funktion f är harmonisk innebär att $\sum_{i=1}^n \frac{\partial^2 f}{\partial x_i^2} = 0$

³Ett vågtåg är flera progressiva vågor vilka periodiskt följer på varandra i utbredningsriktningen.

storleksordning som tryckvågornas våglängd härleder han istället följande ekvation för tryckvågen:

$$\Phi = -\frac{\sigma \cos(2\sigma(z-h)/c)}{\cos(2\sigma h/c)} \sin(2\sigma t). \quad (5)$$

Här är Φ en skalärpotential för rörelsen, σ är tryckvågornas frekvens, z är avståndet från ytan, h är havsdjupet, c är tryckvågornas hastighet i vatten och t är tiden. Vi ser här att Φ går mot oändligheten när $\cos(2\sigma h/c)$ går mot noll. Detta motsvarar resonans och sker för

$$2\sigma h/c = \left(n + \frac{1}{2}\right) \pi \quad (n = 0, 1, 2, \dots), \quad (6)$$

det vill säga när havsdjupet delat på tryckvågornas våglängd är lika med $n + \frac{1}{2}$, ($n = 0, 1, 2, \dots$). Från detta drar Longuet-Higgins slutsatsen att det för ett givet djup finns en resonansfrekvens för tryckvågen som skulle ge upphov till mikroseismik med fem storleksordningar större amplitud än om frekvensen inte är i resonans.

Han inför sedan variablerna Ω_1 och Ω_2 som spektralarean för två vågtåg respektive och Ω_{12} är spektralarean som Ω_1 och $-\Omega_2$ delar. Spektralarean för ett vågtåg är det område inom vilket vågtågets olika vågvektorer ligger. Dessutom definierar han Λ som arean på vilken vågtågen befinner sig och σ_{12} som medelvärdet av vågornas frekvens över Ω_{12} . Han härleder också ett uttryck för det kvadratiske medelvärdet av havsbottnens respons på tryckvågorna, \overline{W} , som avtar med $\frac{1}{\sqrt{r}}$. Från detta får han sedan följande formel för den seismiska amplituden på det horisontella avståndet r från ursprunget

$$\delta \approx 4\pi\rho a_1 a_2 \sigma_{12}^2 \sqrt{\Lambda \Omega_{12} / \Omega_1 \Omega_2 \overline{W}} (2\sigma_{12}, r) e^{2i\sigma_{12}t}. \quad (7)$$

År 2007 presenterade Toshiro Tanimoto en alternativ metod för att härleda sambandet mellan vågor och mikroseismik [10]. Han utgick ifrån hur vågor exciterar normalmoder och fick genom detta en formulering som baserades på havets egenvibrationer. Tanimoto visade att om han gjorde samma antaganden som Longuet-Higgins gjort i sin teori [3] blev hans resultat ekvivalent med Longuet-Higgins. I en senare artikel från 2013 [5] använder Tanimoto sin normalmodsförmulering för att bland annat modifiera Longuet-Higgins resultat om hur tryckvågornas resonansfrekvensen påverkas av havsdjupet. Tanimotos resultat skiljer sig från Longuet i det att resonansfrekvensen för ett givet djup är något lägre i Tanimotos formulering. Vidare poängterar Tanimoto att genom att observera mikroseismik från land kommer en resonans som är mindre känslig för små variationer i djupet att synas. Det vill säga att en resonansfrekvens svarar mot ett större intervall på havsdjupet. Detta betyder att det är svårare att urskilja mikroseismik som genererats på olika djup.

2.1.2 Experimentella studier av mikroseismik

De senaste två decennierna har många studier om mikroseismik publicerats som till skillnad från Longuet-Higgins [3] och Tanimoto [5] inte härleder den matematiska teorin

bakom uppkomsten mikroseismik utan istället studerar dess korrelation med vågor på havet experimentellt.

Bromirski beskriver hur mikroseismiken med dubbla frekvensen av havsvågorna visar toppar för två olika frekvenser och benämner dem kortperiodisk respektive långperiodisk mikroseismik [11]. Frekvensen för långperiodisk mikroseismik ligger omkring 0.15 Hz medan frekvensen för kortperiodisk är omkring 0.2 Hz eller högre. Eftersom högre frekventa seismiska signaler avtar snabbare med avstånd än de med lägre frekvens har uppmätt kortperiodisk mikroseismik sitt ursprung nära mätstationen och därmed även kusten [10].

Mycket tyder på att mikroseismik uppstår i högre grad kustnära än vad tidigare teorier som Longuet-Higgins [3] och Hasselmann [12] förutsagt [13] [14] [10]. En skillnad mellan mikroseismik med uppkomst nära kusten och sådan med uppkomst i djupare vatten är dessutom att den som uppstår i djupare vatten är mer beroende på att det är storm medan den kustnära är allmänt förekommande [8]. En trolig anledning till detta är att det inte krävs motriktade vågtåg för kustnära uppkomst på samma sätt då dessa omständigheter till exempel kan bildas då vågorna reflekteras mot kusten [7]. Det finns även resultat som tyder på att det bildas sekundär mikroseismik av evanescenta⁴ tryckvågor om djupet är tillräckligt litet [11] [15] [16]. Dessutom har det upptäckts att en betydande del av mikroseismiken består av primära vågor med samma frekvens som vattenvågorna. Dess medelvärde är enbart omkring 20 dB lägre än den sekundära mikroseismikens [17].

I motsats till teorierna om att den största delen av mikroseismiken uppstår på grunt vatten säger Kedar att den största källan till mikroseismik är ett område söder om Grönlands spets där djupet är omkring två till tre tusen meter [7]. Den största anledningen till att just denna plats skulle vara så fördelaktig är att de geografiska och meteorologiska förhållandena gynnar generation av vågor med motsatt rikning [7].

2.2 Mätning av mikroseismik

Tyngdaccelerationen på jordytan uppskattas vanligtvis till $9,82 \text{ ms}^{-2}$ men den är i själva verket inte konstant, varken i tiden eller på olika delar av jorden. Eftersom att tyngdaccelerationen spelar en betydande roll i många fysikaliska processer är det i många fall relevant att mäta den med stor noggrannhet. Till detta används så kallade gravimetrar. En gravimeter är en accelerometer avsedd för att mäta lokal tyngdacceleration. Det som utmärker en gravimeter från en vanlig accelerometer är att den generellt har hög precision och enbart mäter förändringen av accelerationen.

Gravimetern vid Onsala rymdobservatorium (OSO) är en så kallad supraledande gravimeter tillverkad av GWR Instruments [18]. Gravimetern mäter tyngdaccelerationen med en känslighet på 10 pms^{-2} . Mätningen bygger på att ett supraledande niobiumklot leviteras i ett inducerat magnetfält. Genom att mäta förändringarna i kraften som krävs

⁴Evanescenta vågor avtar exponentiellt med avståndet utbredningsriktningen.

för att hålla klotet stationärt går det att extrahera förändringarna i tyngdaccelerationen.

2.3 Matematisk beskrivning av effektspektrum

Det kan ibland vara intressant att studera hur en signals effekt är fördelad över olika frekvenser. För att göra detta är det vanligt att använda sig utav ett effektspektrum som beskriver en funktions varians för olika frekvenser. Effektspektrumet P_{xx} definieras som fouriertransformationen av autokovariansfunktionen γ_{xx} , det vill säga

$$P_{xx} = \mathcal{F}(\gamma_{xx}) = \sum_{m=-\infty}^{\infty} \gamma_{xx}(m) e^{-j\omega m} \quad (8)$$

där

$$\gamma_{xx}(m) = E[(x_n - m_x)(x_{n+m}^* - m_{x^*})] \quad (9)$$

och E står för väntevärdet, x^* är det komplexa konjugatet till x och m_x dess medelvärde.

Om vi låter x vara en svagt stationär stokastisk process, alltså en process med tidsberoende medelvärde och varians och dessutom antar att $m_{x^*} = m_x = 0$.⁵ Då blir

$$\gamma_{xx}(m) = E[x_n x_{n+m}^*] \quad (10)$$

som för svagt stationära processer är lika med autokorrelationsfunktionen⁶, $R_{xx}(j)$, vilken definieras som

$$R_{xx}(j) = \sum_{n=-\infty}^{\infty} x_n x_{n-j}. \quad (11)$$

Om då $\mathcal{F}(x) = X(\omega)$ då får vi att

$$P_{xx} = \mathcal{F}(R_{xx}) = \mathcal{F}(x_n)(\omega) \mathcal{F}(x_n^*)(\omega) = |X(\omega)|^2. \quad (12)$$

I praktiken, när det är finita signaler som betraktas, så är det inte längre möjligt att bestämma effektspektrumet entydigt. Istället uppskattas effektspektrumet för den bakomliggande, ofta kontinuerliga, signalen. Problemet är att det uppstår så kallat spektralt läckage eller sidlobar vid multiplikation av en signal med en tidsberoende funktion. Det innebär att en del av effekten läcker övertill närliggande frekvenser. I detta fall är dessa tidsberoende funktioner en stegfunktion över det intervall datan finns vilken representerar att signalen är finit och en summa av deltafunktioner som representerar samplingen.

⁵Detta är inte strikt nödvändigt men gör kommande beräkningar simplare samt tar bort fouriertransformen av en konstant term som ger utslag vid noll som ofta är ointressant

⁶Beroende på definition kan det skilja en konstant faktor här vilken dock är irrelevant

För att uppskatta effektspektrum finns det flera olika metoder och dessa kan enklast delas upp i två olika grupper, parametriska och icke-parametriska. Parametriska modeller går ut på att datan antas vara stationär och att den följer en viss fördelning och sedan försöker anpassa parametrar så att datan stämmer överens så bra som möjligt. Icke-parametriska modeller gör inga sådana antaganden utan använder endast datan för att skapa spektrum.

Ett enkelt sätt att uppskatta effektspektrumet är genom ett så kallat periodogram där autokovariansen $c_{xx}(m)$ skattas som

$$c_{xx}(m) = \frac{1}{N} \sum_{n=0}^{N-|m|-1} x(n)x^*(n-m) \quad (13)$$

och sedan beräknar dess diskreta fouriertransform

$$C(\omega) = \sum_{n=0}^{N-1} c_{xx}(m)e^{-j\omega m}. \quad (14)$$

Detta är en ganska dålig skattning av effektspektrumet, till exempel så minskar inte variansen med ökat N [19], men många metoder utgår ifrån periodogrammet och gör förbättringar på det.

Ett verktyg för att förändra skattningens egenskaper är att falta den med en ett spektralt fönster $W(\omega)$. Ett spektralt fönster är fouriertransformen av fönsterfunktion $w(n)$ och en fönsterfunktion är en funktion som är noll utanför ett visst intervall⁷. Eftersom en faltning i frekvensrummet är ekvivalent med en multiplikation i tidsrummet innebär det att den modifierade skattningen blir,

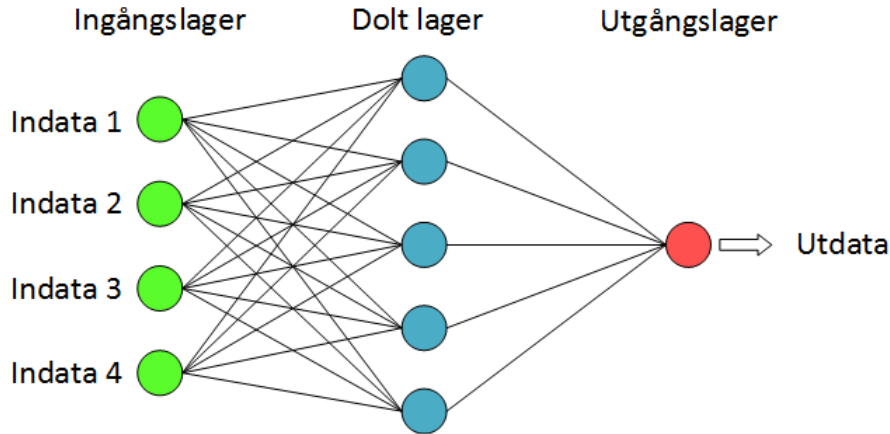
$$S_{xx}(\omega) = W * Y(\omega) = \sum_{m=-(M-1)}^{M-1} y_{xx}(m)w(m)e^{-j\omega m}, \quad (15)$$

om vi låter $Y(\omega)$ vara den ursprungliga skattningen. Att applicera ett fönster kan leda till att effektspektrumet får negativa värden om inte $W \geq 0$. Eftersom det handlar om effekt är det dock naturligt att studera storleken snarare är värdet på effektspektrumet genom att ta absolutbeloppet av värdena.

2.4 Artificiella neurala nätverk

Det nätverk av hjärnceller som bygger upp hjärnan hos människan är ett exempel på ett biologisk neuralt nätverk. Nätverket är mycket komplicerat och kan lösa många problem

⁷Går även att definiera så att det räcker att de avtar snabbt



Figur 2: **Framåtmatande neuralt nätverk.** Bilden illustrerar ett framåtmatande nätverk med fyra ingångs-neuroner, ett gömt lager med fem neuroner och en utgångslager med en neuron. Till varje koppling mellan neuroner en tillhörande vikt som viktar indatan till nästa neuron.

som många tekniker inte kan. Det har därför väckts ett intresse att efterlikna dessa neurala nätverk på konstgjord väg och dessa brukar kallas ANN (Artificiella neurala nätverk) [20]. ANN består av en mängd neuroner (noder) kopplade till varandra i ett nätverk vilket efterliknar hjärnans synapser. Varje neuron realiserar som en funktion $y = f(x_1, x_2, \dots, x_n; w_1, w_2, \dots, w_n)$ där x_i är variabler och w_i är vikter för varje variabel. Vanligtvis är det önskvärt att f är en icke-linjär och begränsad funktion. Exempel på vanliga sådana funktioner är tangens hyperbolikus eller sigmoid-funktionen⁸. Indatan till varje neuron är viktad. Vikterna används för att vikta indatan och således reglera utdatan. Varje neuron kan även ha ett tröskelvärde vilket är ett värde som indatan vid varje enskild ingång måste överstiga för att neuronerna inte ska ha noll som utdata. Tröskelvärdet kan därmed användas för att undvika att nätverket hittar samband mellan små värden som är irrelevanta.

Den vanligaste typen av neuralt nätverk är ett så kallat framåtmatande nätverk som illustreras i figur 2. När värdet på funktionen y hos neuronerna är beräknat skickas utdatan vidare till nästa lager som då beräknar värdet på sina funktioner. Framåtmatande nätverk innebär att flödet från ingångs-informationen enbart går "framåt" i nätverket och inte återkopplas till tidigare lager. Nätverket i figur 2 har ett ingångslager och ett utgångslager av neuroner. Just i figur 2 finns det ett dolt lager mellan ingångslagret och utgångslagret.

Fördelen med ANN är att de kan lära sig olika samband genom ändring av vikterna på varje nodingång. Eftersom ANN har möjlighet att lära sig olika samband kan de lösa problem som är näst intill omöjliga med andra metoder. ANN är mycket lämpliga för

⁸ $S(t) = \frac{1}{1-e^{-t}}$

bland annat mönsterigenkänning och informationsutvinning och tillämpas till exempel till prognoser inom meteorologi [21] och finans [22].

Ett neuralt nätverk kräver en inlärningssession där vikterna bestäms. För ett framåtmatande nätverk är elastisk fortplantning en av de vanligaste inlärningsalgoritmerna. Inlärningsmetoden är av typen styrd träning vilket innebär att indatan till nätverket jämförs direkt med det resultat som indatan skall svara mot, den så kallade träningsmängden. Det är därmed viktigt att indatan och resultatet i träningsmängden speglar det samband som verkligen finns. Om nätverket har som uppgift att tränas till att kunna avgöra om en person ler, gråter, blundar eller inget av dem i en bild skall indatan till nätverket vara till exempel intensitetsskillnader mellan pixlarna i bilder där personen gör en av de nämnda gesterna. Resultat som indatan jämförs med skall i detta fall vara en siffra som motsvarar den korrekta gesten.

Att träna nätverket innebär att minimera felet, det vill säga den kvadratiske skillnaden mellan alla punkter i utdatan från nätverket och det korrekta resultat som önskas uppnås. Minimeringen sker genom en stegvis ändring av vikterna så att felet avtar. I elastisk fortplantning beräknas tecknet på de partiella derivatorna hos felet med avseende på vikterna. Vikterna ändras sedan med $\Delta\omega_{ij}^{(t)}$ vid varje iteration t enligt

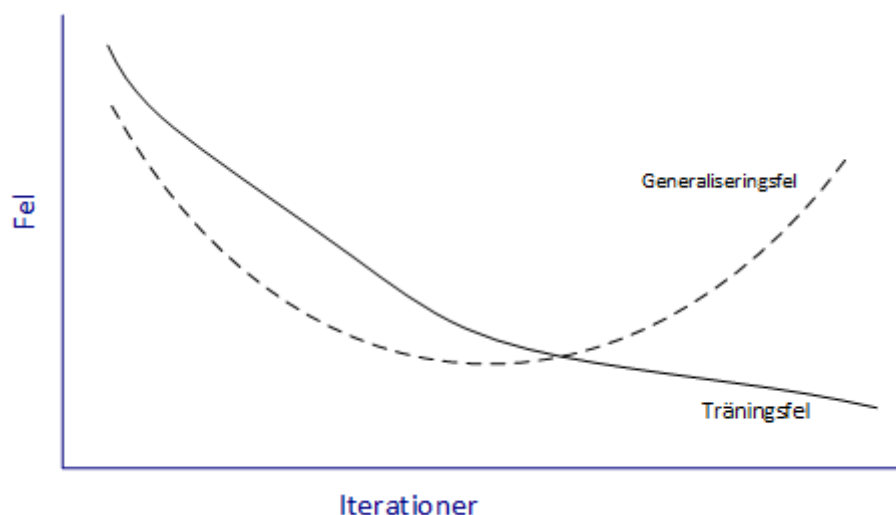
$$\Delta\omega_{ij}^{(t)} = \begin{cases} -\Delta_{ij}^{(t)}, & \frac{\partial E}{\partial \omega_{ij}^{(t)}} > 0 \\ +\Delta_{ij}^{(t)}, & \frac{\partial E}{\partial \omega_{ij}^{(t)}} < 0 \\ 0, & \text{annat fall} \end{cases} \quad (16)$$

där i är index för vikten hos neuron j och E är felet. Uppdateringsvärdet $\Delta_{ij}^{(t)}$ beräknas enligt

$$\Delta_{ij}^{(t)} = \begin{cases} \eta^+ \cdot \Delta_{ij}^{(t-1)}, & \frac{\partial E}{\partial \omega_{ij}^{(t-1)}} \cdot \frac{\partial E}{\partial \omega_{ij}^{(t)}} > 0 \\ \eta^- \cdot \Delta_{ij}^{(t-1)}, & \frac{\partial E}{\partial \omega_{ij}^{(t-1)}} \cdot \frac{\partial E}{\partial \omega_{ij}^{(t)}} < 0 \\ \Delta_{ij}^{(t-1)}, & \text{annat fall} \end{cases} \quad (17)$$

där η^+ och η^- är det positiva respektive negativa stegvärdet, vanligtvis $\eta^+ = 1.2$ och $\eta^- = 0.5$. Proceduren repeteras till felet är mindre än det valda gränsvärdet eller felet inte längre minskar.

I de flesta fall är in- och utdatan full av brus som inte bidrar till det samband som önskas hittas. Träningsmetoden, som minimerar felet mellan nätverkets resultat och det önskade, tar inte hänsyn till att bruset inte skall väga in i resultatet. Nätverket kommer därmed att finna samband mellan bruset i indatan och utdatan, en oönskad biverkan. För att minimera brusets påverkan på resultatet vore det därför optimalt om det generella felet kunde hittas. Med det generella felet menas i princip hur bra nätverket generellt finner de önskade sambanden. Att finna det generella felet är oftast inte möjligt och även bra approximationer kan vara svåra att finna. Ofta används verifieringsdata för att



Figur 3: **Illustration av generaliseringsfel mot träningsfel.** *Principskiss över generaliseringsfelet jämfört med träningsfelet som funktion av antalet iterationer. Det generella felet når ett minimum efter ett antal iterationer medan träningsfelet går mot noll när antalet iterationer ökar. Detta är för att nätverket övertränar mot sin träningsdata.*

uppskatta det generella felet, alltså data som är likadan som träningsmängden men som inte är med i den. För att uppnå bästa resultat önskas det generella felet minimeras. I figur 3 visas principen över hur det generella felet förhåller sig till felet mellan nätverket och träningsmängden. Vi ser att om nätverket tränas för långt mot träningsdatan kommer det att övertränas, det vill säga att det anpassar sig mot datan snarare än mot sambandet. Det innebär att om ny indata används så kommer nätverket att ha utdata som är starkt präglad av träningsdatan. Detta medför sämre uppskattning av de generella sambanden och då att det generella felet ökar.

Strukturen för ett framåtmatande neuralt nätverk är simpel. Det återstår dock att välja antalet gömda lager samt antalet neuroner på respektive lager. I de allra enklaste fallen är det möjligt att analytiskt finna det optimala antalet lager samt neuroner. När antalet indata ökar och sambandet som söks är okänt blir det genast en mer komplicerad procedur. I de flesta fall finns det inget sätt att bestämma antalet lager samt neuroner utan att skapa nätverken och jämföra dem. Enligt Warren S. Sarle [6] räcker det i de flesta fall, som inte är alltför komplicerade, med ett gömt lager. På liknande sätt som vi kunde överträna nätverket ovan på grund av för många träningsiterationer kan nätverket överbestämmas genom att använda för många neuroner. Träningsfelet jämfört med ge-

neraliseringsfelet med avseende på antal neuroner förhåller sig till varandra med samma princip som med avseende på antal iterationer illustrerat i figur 3.

3 Verkställande av korrelationsmodell

Vi har i vårt arbete korrelerat data över våghöjd på Atlanten med effektspektrumet av tyngdaccelerationsdata med hjälp av ett artificiellt neuralt nätverk. Det första steget i processen var att behandla tyngdaccelerationssignalen från gravimetern för att reducera störningar. Vi producerade sedan ett effektspektrum utifrån denna behandlade signal. Data över våghöjden fick vi från ECMWF och denna behandlade vi till exempel genom att minska datans upplösning. Effektspektrumen och den behandlade våghöjdsdatan användes för att träna ett artificiellt neuralt nätverk att kunna simulera effektspektrum utifrån vågdata. Detta program användes sedan för att dra slutsatser om mikroseismik genom att låta nätverket simulera effektspektrum utifrån konstgjord våghöjdsdata. Denna konstgjorda data skapades enligt hypoteser baserad på befintliga teorier om mikroseismik för att se om vi kunde se relationer till dessa.

3.1 Förbehandling av gravimeterdata


Innan vi kan skapa ett effektspektrum av gravimeterdatan måste datan förbehandlas för att reducera effekter från oönskade signaler. Då signalen samplas en gång per sekund blir den högsta mätbara frekvensen (Nyquistfrekvensen) 0,5 Hz. Det betyder att det inte går att få ut någon information från signaler med högre frekvens än 0,5 Hz. I gravimeterdatan finns det dock frekvenskomponenter för frekvenser större än 0,5 Hz vilka inte kan samplas. Dessa signaler kommer istället att feltolkas som frekvenser lägre än Nyquistfrekvensen och ge upphov till så kallad vinkningsdistortion⁹. För att minimera vinkningsdistortionen används ett lågpasfilter¹⁰ enligt figur 4. Detta filter dämpar signaler med frekvens över Nyquistfrekvensen med mer än 100 dB vilket eliminerar majoriteten av vinkningsdistortionen.

Det finns källor till variation i tyngdaccelerationen som stör den sökta signalen. Den största variationen genereras av periodiska fluktuationer i tidvattenkraften. Dessa fluktuationer beror både på att jorden roterar kring sin egen axel och att månen roterar kring jorden vilket leder till att jordens och månens gemensamma masscentrum inte är stationärt relativt en punkt på jordens yta. Nettoeffekten av tidvattenkrafterna kan approximeras med hjälp av matematiska modeller och med hjälp av dessa har vi korrigerat för tidvattnets påverkan på mätdatan.

Utöver tidvattenkraften påverkas tyngdaccelerationen även av lokala väderförhållanden. Om det är ett lokalt högtryck vid Onsala Rymdobservatorium kommer ytnära vatten nära observatoriet att pressas ut på havet och om det är lågtryck kommer vattnet istället dras in mot observatoriet. Nettoeffekten på tyngdaccelerationen från tryckskillnader

⁹Ofta beskrivs det som att högfrekventa signaler "viks ner".

¹⁰Eftersom ett lågpasfilter sänker amplituden markant på frekvenser över Nyquistfrekvensen reduceras vinkningseffekten.



Figur 4: Bodediagram över gravimeterns lågpassfilter. Bilden visar dämpningen och fasförskjutningen i filtret som används för att minska vinkningsdistortioner i gravimetern. Signalens dämpning plottas i svart och dess fasförskjutning i blått. Vi ser att vid nyquistfrekvensen är dämpningen 100dB vilket räcker för att eliminera vinkningsdistortionen vid vanligt körning.

approximeras linjärt och subtraheras från signalen. Signalen som då kvarstår består huvudsakligen av mikroseismik samt störningar från jordbävningar och dess efterskalv.

Jordbävningar ger brus i datan som har en allt för stor inverkan på effektspektrumet för att inte störa våra samband. De sker visserligen inte i ett frekvensområde där mikroseismik verkar. De har dock en amplitud som är många gånger större än mikroseismiken och riskerar därmed att dränka de svagare signalerna som mikroseismiken ger upphov till med sina sidlobber, se avsnitt 2.3. Därför har ett filter skapats för att sortera bort data som innehåller jordskalv. Filtret beräknar ett kvadratisk medelvärde över perioder på 10 minuter. Om det kvadratiske medelvärdet överstiger ett specifikt värde eller om två följande kvadratiske medelvärden skiljer sig med en för stor faktor tas datan i närheten av störningen bort och används inte i senare bearbetning. Även när enstaka datapunkter kraftigt överstiger normala värden för stormiga dagar görs samma bortsortering. Eftersom jordskalv ger upphov till starkare oscillationer än mikroseismik innebär det att perioder med jordskalv har högre kvadratiske medelvärden men även värden överlag. Jordskalven kommer plötsligt och är ofta mycket begränsade i tid vilket medför att det går att upptäcka skillnader mellan sekventiella kvadratiske medelvärden. Det är dock inte helt oproblemiskt att sortera bort jordskalv, det är viktigt att inte stormiga dagar sorteras bort för att de har för stort medelvärde och att lugna dagar med små störningar inte sorteras bort för då riskerar vi att få träningsdata som inte är representativ för verkligheten. För att undvika detta har vi valt att ha relativt krävande gränser för vad som sorteras bort vilket innebär risk för att jordskalv tar sig igenom men samtidigt minskar risken för att intressant data av en viss typ saknas i träningsmängden.

3.2 Konstruktion av effektspektrum från gravimeterdata

För att studera frekvensspektrumet av gravimetersignalen har vi uppskattat dess effektspektrum. Vi valde i vårt arbete att använda en icke-parametrisk modell för att undvika att behöva göra några antaganden i förväg, se avsnitt 2.3. En nackdel med icke-parametriska metoder är att spektrumet får ett lite kaotiskt utseende. Neurala nätverk bör dock kunna sortera bort bruset som uppstår och det finns även teori som hävdar att neurala nätverk presterar bättre på okänd data (data de inte tränats mot) om de tränats mot data med mycket störningar [23].

Vi valde i vårt arbete att implementera en algoritm för effektspektrum själva vilket både har fördelar och nackdelar. De två nackdelarna som finns är risken för att algoritmen inte blir rätt implementerad och att det tar lång tid att göra det. Risken med att använda en färdig algoritm är att en stor del av förståelsen som kommer med implementeringen inte uppstår. Det är inte rimligt att implementera allting själv men när är en väldigt central del av det som ska göras samtidigt som det inte är alltför komplicerat kan det vara värt att implementera själv.

Vi använder oss i våra beräkningar av en algoritm beskriven på s560-562 i Digital Signal Processing av Oppenheim och Schaffer [19]. Den går ut på att ett triangulärt

fönster appliceras på autokovariansfunktionen, se ekvation (13). Ett triangulärt fönster ges av

$$\begin{cases} w(n) = 1 - \frac{|n|}{M-1}, & -(M-1) \leq n \leq M-1 \\ 0, & \text{annars} \end{cases} \quad (18)$$

vilket i detta fall innebär att vi viktar ner autokovariansen linjärt tills den blir 0 vid $\pm(M-1)$. Genom att utnyttja detta kan vi dela upp spektrumet delar med längd M . Om vi dessutom utnyttjar att $c(-m) = c(m)$ räcker det att uppskatta för $m \geq 0$, detta tillsammans med att $x(n)$ är reell i vårt fall gör att vi kan skriva ekvation (13) som

$$c_{xx}(m) = 1/N \sum_{i=1}^K \sum_{n=0}^{M-1} x(n + (i-1)M)x(n + (i-1)M + m). \quad (19)$$

Vi kan alltså dela upp den i bitar när vi explicit ska beräkna autokorrelationen. Om vi sätter

$$x_i(n) = \begin{cases} x(n + (i-1)M), & 0 \leq n \leq M-1 \\ 0, & M \leq n \leq L-1 \end{cases} \quad (20)$$

och

$$y_i = x(n + (i-1)M), \quad 0 \leq n \leq L-1 \quad (21)$$

där $L \geq 2M-1$ så är ekvation (19) lika med

$$1/N \sum_{i=1}^K \sum_{n=0}^{M-1} x_i(n)y_i(n+m) \quad (22)$$

för $0 \leq m \leq M-1$. Genom några algebraiska omvandlingar går det sedan att beräkna ekvation (19) med få beräkningar, en önskvärd egenskap med tanke på vår relativt höga mängd data. Vi slätar sedan ut spektrumet genom att applicera ett så kallat Kaiser-Bessel fönster på vår uppskattade autokorrelation. Fönstret ges av

$$w(n) = \frac{I_0\left(\pi\alpha\sqrt{1 - \left(\frac{2n}{N-1}\right)^2}\right)}{I_0(\pi\alpha)} \quad (23)$$

med $\alpha = 2.4$ och där I_0 är nollte ordningens modifierade Bessel funktion. Det har en relativt smal huvudlob så den behåller värdena bra men den har framför allt en väldigt bra dämpning av sidloben. Sidlobsdämpning är storleksförhållandet mellan huvudloben och efterföljande loberna som kommer av det spektrala läckaget. Det neurala nätverket lär inte påverkas så mycket utav minskad upplösning eftersom det försöker hitta de generella sambanden och det är viktigare att sortera bort en del av variansen (eftersom faltningen motsvarar någon form av viktat medelvärde av punkter så måste den minska). Vi vill dock samtidigt inte att stora värden på en plats ska ge utslag på värden långt därifrån, det är

därför acceptabelt med en ganska bred huvudlob men det är viktigt att sidlobsdämpningen är stor.

Efter att de ska ha filtreras bort återstår det fortfarande processer med låga frekvenser i vår gravimetersignal, x_n , som respåverkan från tidvatten. Vi undviker detta genom att istället titta på skillnaden mellan värdena i signalen. Detta motsvarar att använda ett så kallat differens-filter dvs. att transformera

$$z_n = x_n - \alpha x_{n-1}. \quad (24)$$

Vi behöver också subtrahera medelvärdet från z_n för att uppfylla $m_z = 0$; z_n blir då svagt stationär. Efter att sedan ha beräknat spektrumet för z_n kan vi sedan återtransformera enligt

$$\frac{P(\omega)_{zz}}{|1 - \alpha e^{j\omega}|^2} = P_{xx}(\omega)$$


för att återfå det ursprungliga effektspektrumet [24].

3.3 Förbehandling av vågdata

Våghöjdsdatan som vi försöker korrelera mot effektspektrumet på gravimeterdatan kommer ifrån från ECMWF (European Center for Medium Range Forecasts). Den har en spatial upplösning på åtta punkter per grad longitud eller latitud (64 punkter per kvadratgrad) och en temporal upplösning på 4 mätserier per dygn. Vi har valt att använda oss av data från området som sträcker sig mellan N35° - N70° och W70° - E15°, se figur 5, eftersom att detta område är stort nog för att täcka de regioner som vi väntar oss ska ge upphov till majoriteten av den uppmätta mikroseismiken. Vi valde att behålla avstånden mellan datapunkterna i samma form som ECMFW använder vilket innebär att det finns lika många datapunkter på varje latitud oberoende av longitud. Detta sätt att projicera data brukar kallas ekvirektangulär projektion.

Ett problem är att det i vissa mätserier saknas datapunkter från vissa platser vilket måste hanteras innan vi använder datan i det neurala nätverket. Detta eftersom att datan sparas som en vektor där varje element svarar mot en koordinat. Om några av elementen saknas förskjuts resterande element vilket betyder att det neurala nätverket försöker korrelera data med fel koordinater. Majoriteten av den saknade datan är lokaliserad nära kuster och generellt i den norra delen av vårt område. Eftersom mikroseismik främst uppkommer antingen på djupare vatten eller nära mätstationen är det rimligt att anta att vågorna som motsvaras av den saknade datan inte har stor inverkan. En lösning skulle kunna vara att ersätta den saknade datan med ett konstant värde (till exempel noll). Den här metoden brister dock något när våghöjden i de saknade punkterna skiljer sig markant från de fixa värdena.

Vi valde istället att dela upp området i zoner som är en breddgrad gånger en längdgrad stora och ta medelvärdet över all tillgänglig data inom zonen. Vi sökte följaktligen genom




Figur 5: **Karta över området från vilket vi hämtar vår våghöjdsdata.** Kartan visar området mellan $N35^\circ$ - $N70^\circ$ och $W70^\circ$ - $E15^\circ$. Det blåmarkerade området visar ifrån vilka zoner vi hämtade vår våghöjdsdata. Kravet för att en zon ska inkluderas i datamängden är att det alltid måste finnas våghöjdsdata för minst 8 av de 64 punkterna inom zonen. Att det saknas våghöjdsdata i en punkt kan bero på att punkten ligger på land eller om havet är täckt av is.

hela datamängden och hittade de zoner som vid alla tidpunkter hade data i minst 8 av 64 datapunkterna i området. Genom att bara använda dessa zoner som indata till vårt neurala nätverk säkerställde vi att alla element i vår vågdata fanns vid alla tidpunkter. På så sätt undviker vi de fel som skulle uppstå om vi satt fixa värden mot att vi förlorar en del datapunkter runt Grönlands och Nordamerikas kust.

En annan fördel med att ta ett medelvärde av den förhållandevis högupplösta datan är att storleken på indatan minskas samtidigt som formen och magnituden på våghöjdsdatan bevaras. Detta är önskvärt då antalet nödvändiga beräkningar i det neurala nätverket ökar exponentiellt med antalet dimensioner i indatan. Dessutom krävs det fler träningsiterationer för att bestämma vikterna i det neurala nätverket om mer indata används. Förlusterna i upplösning är inget problem då stormar tenderar att sträcka sig över tiotals kvadratgrader vilket syns i figur 6.

3.4 Korrelation genom artificiella neurala nätverk

Det framtagna effektspektrumet från gravimeterdatan och vågdatan analyserades med ett neuralt nätverk av typen framåtmatande nätverk. Ett framåtmatande nätverk valdes till följd av dess enkla struktur och förmåga att lösa många typer av problem där ett neuralt nätverk är av intresse. Ingångslagret skapades med samma antal neuroner som områden med vågdata enligt avsnitt 3.3. Varje neuron i ingångslagret motsvarade därmed ett



Figur 6: Bild på våghöjd vid under en storm på Nordatlanten, 2010-11-08. Ett exempel på hur våghöjden kan se ut under en storm på Nordatlanten. Notera att stormen sträcker sig över tiotals grader latitud och longitud.

specifikt geografiskt område på Atlanten. Utgångslagret skapades på samma sätt med lika många neuroner som datapunkter i effektspektrumet, vilket var 584 stycken. Nätverket skapades med ett dolt lager för enkelhet samt att det i de flesta fall är tillräckligt som nämnts i teoriavsnittet 2.4 om ANN.

3.4.1 Val av antal neuroner i det gömda lagret

Antalet neuroner i det gömda lagret valdes genom att jämföra hur väl nätverk med olika antal neuroner generaliserade det sökta sambandet. Datan från effektspektrumet och havsvågorna delades upp i en träningsmängd samt en testmängd. Träningsmängden innehöll data från 100 dagar som slumpades fram av den totala datan från effektspektrumet och havsvågorna. Testmängden bestod av de resterande 18 dagarna av den tillgängliga datamängden. Träningsmängden användes för att träna nätverket medan testmängden användes för att göra en approximation av det generella felet F_{gen} . Det generella felet approximerades genom att mata nätverket med data från testmängden och beräkna den kvadratiska skillnaden mellan nätverkets utdata $Y_{network}$ och den riktiga datan Y_{test} i testmängden enligt

$$F_{gen} = \sum_{i=1}^N [Y_{net}(i) - Y_{test}(i)]^2$$

där N är antalet datapunkter.

Ett nätverk med en enstaka neuron i det gömda lagret tränades och för varje träningsiteration sparades träningsfelet F_{train} samt approximationen av det generella felet. Utförandet upprepades för nätverk med antalet neuroner mellan 1 och 581. Med ökat antal neuroner i ett nätverk ökar antalet träningsiterationer som krävs för att förändringshastigheten hos träningsfelet ska hamna inom ett tillräckligt litet området kring noll. I syfte att låta varje nätverks träningsfel stagnera nära sitt minimum körde varje nätverk ett stort antal träningsiterationer. Antalet iterationer valdes till 1000 eftersom detta var mer än tillräckligt för att nätverket med 581 neuroner skulle stagnera nära sitt minimum. Att köra 1000 iterationer på varje nätverk var mycket tidskrävande och därför valdes antalet neuroner i nätverken att öka med 20 vid varje steg. Detta gav en överblick hur felet ändrades som funktion av neuroner och en mer noggrann körning kunde göras. Denna gång tränades varje nätverk mellan 1 och 100 neuroner. För varje nätverk framtogs ett minimum av det approximerade generella felet samt träningsfelet bland träningsiterationerna. Enligt resultatet som presenteras i avsnitt 4.1 valdes antalet neuroner till 50 och antalet iterationer till 50 i nätverket som användes i fortsättningen.

Det färdigtränade nätverkets prestanda undersöktes till sist genom att manuellt jämföra nätverkets resultat med de verkliga resultaten. Effektspektrumen skapade av nätverket plottades i samma graf som de verkliga effektspektrumen för ett antal sextimmarsintervall. Den jämförda datan var dels från träningsmängden och dels från testmängden. På så sätt kunde vi enkelt få en uppfattning om hur väl nätverket speglade de verkliga sambanden samt om nätverket var övertränat eller undertränat.

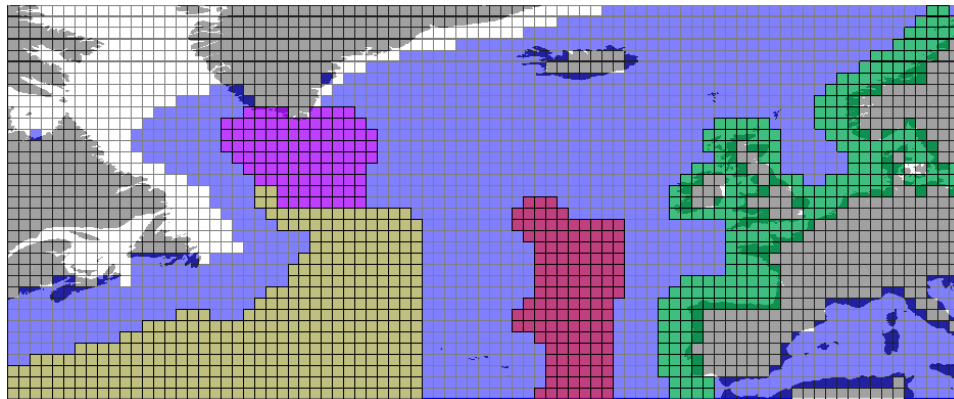
3.4.2 Analys med hjälp av det tränade nätverket

För att kunna dra slutsatser från det tränade nätverket använde vi oss av konstgjord våghöjdsdata. Det färdigtränade nätverket återspeglar korrelationer mellan våghöjden i specifika zoner och amplituden för specifika frekvenser i ett effektspektrum. Det finns dock inget enkelt sätt att extrahera dessa samband helt perfekt. För att undersöka korrelationer kan nätverket utnyttjas genom att manipulera indata. Genom att styra indata till valda funktioner och samband kan nätverkets svar på datan kartläggas.

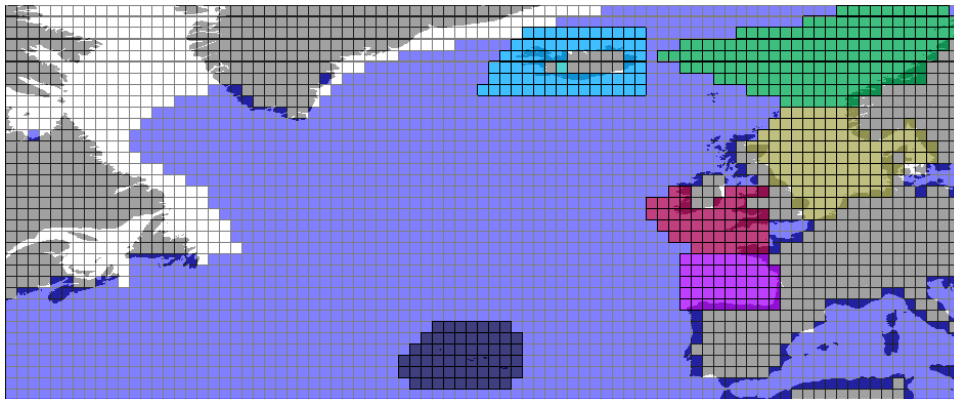
Vi utgick från våghöjdsdata från en väldigt lugn dag (26 juli 2010) och höjde sedan våghöjden i specifika zoner. Denna konstgjorda data användes sedan som indata i det tränade neurala nätverket. Området där vågdatan hämtades ifrån delades upp i mindre områden av en bestämd storlek, områdena tilldelades vågor av en viss höjd medan resterande områden hade kvar vågor från vår lugna dag. Genom denna metod ville vi kartlägga vilka geografiska platser som gav stort respektive litet utslag hos gravimetern samt våghöjdens påverkan.

De områden vi valde att undersöka syns i figur 8. Områdena valdes i syfte att studera de samband som framlades i teoriavsnittet. Enligt teoriavsnittet är mikroseismiken uppdelad i två frekvensområden, primär mikroseismik och sekundär mikroseismik. Större delen av den sekundära mikroseismiken har sitt ursprung i djupare delar av havet medan den primära härstammar från grundare områden. För att undersöka validiteten hos teorin valde vi att dela upp havet i grunda och djupa områden. Till vår hjälp hade vi figur 9 där som visar havsdjupet vid olika områden på Atlanten. Enligt Kedar kommer det största bidraget till mikroseismiken ifrån området söder om Grönland [7], av denna anledning undersöker vi även detta område. Området runt Biscayabukten undersöktes på grund av att havet snabbt går från grunt till djup vid den så kallade kontinentalsockeln. Denna struktur möjliggör stark reflektion av vågor eftersom de inte försvagas i samma grad som de skulle gjort om djupet avtog långsamt. De inkommande vågorna tillsammans med de reflekterade vågorna kan därmed skapa sekundär mikroseismik. Norges kust undersöktes även på grund av av samma anledningar Biscayabukten. Bromirski skriver att sekundär mikroseismik avtar mycket snabbt med ökat avstånd från källan [11]. Området intill gravimetern, det vill säga Nordsjön, granskades därför. Området runt Azorerna intresserade oss även för deras säregna belägenhet mitt på kontinentalryggen. Vi valde även en blandning av både djuphav och kustområden för att kunna jämföra dessa områdens påverkan.

För att undersöka vilka områden som ger upphov till stark mikroseismik såg vi till nätverkets respons till små vågområden. Detta fungerade på samma sätt som för tidigare undersökning med områden från figur 8, skillnaden är att den manipulerade datan är mycket mer lokal. För varje punkt i figur 5 så ändrades vågdatan så att punkten fick 14 m våghöjd och de 8 kringliggande punkterna fick 10 m våghöjd. Datan användes sedan som indata till nätverket och det simulerade effektspektrumet summerades för att ge ett mått på den totala mikroseismiken som punkterna gav upphov till.




(a)



(b)

Figur 8: **Områden som undersöks med genererad våghöjdsdata.** De områden som användes för att generera våghöjdsdata. Figur (a) visar det stora kustområdet i grönt, nord-östra Labradorhavet i lila samt östra och västra djuphaven i gult respektive rött. Figur (b) visar Norska havet i grönt, Nordsjön i gult, Keltiska havet i rött, Biscayabukten i lila, Islands kust i turkos samt havet kring ögruppen Azorerna i svart.



Figur 9: **Karta över havsdjupet** *Havsdjupet i meter ritat för området mellan $N35^\circ$ - $N70^\circ$ och $W70^\circ$ - $E15^\circ$.*

3.5 Realisering av det artificiella neurala nätverket

Mätvärden från gravimetern och våginformation från Onsala rymdobservatorium samt ECMWF hämtades ner för ett antal utvalda dagar. Gravimeterdatan filtreras från jordskalv enligt avsnitt 3.1 för att sedan delas upp i intervall på sex timmar vardera. Varje intervall transformeras då till ett effektspektrum enligt metoden i avsnitt 3.2. Vi bygger sedan upp ett nätverk som är av typen framåtmatande nätverk och det tränas med elastisk fortplantning. Innan programmet färdigställer det slutliga nätverket skapas ett bestämt antal nätverk med olika antal neuroner. Dessa nätverk tränas och deras generella fel jämförs enligt metoden i avsnitt 3.4. På detta sätt kan en uppskattning av det mest optimala antalet neuroner finnas. Nätverket med det minsta generella felet skapas på nytt och tränas återigen. Slutligen när det neurala nätverket är tränat testas det på ny indata motsvarande stormar vid olika geografiska områden enligt avsnitt 3.4.2.


4 Resultat

Resultatet för undersökning av möjligheten till korrelationen mellan våghöjd och effektspektrum genom artificiella neurala nätverk är blandade. De effektspektrum som nätverket simulerat utifrån riktig data stämmer oftast ganska väl med det uppmätta resultatet men avviker ibland en del, framförallt för låga amplituder på det riktiga spektrummet. Spektrummen som nätverket simulerat utifrån konstruerad data visar på att den uppmätta mikroseismiken skulle ha högre amplitud för höga vågor i områden på och i närheten av kontinentalsockeln under Europa.


4.1 Träning- och generaliseringsfel vid optimering av neuronantal

Resultatet från testet av det optimala antalet neuroner i det gömda lagret syns i figur 11. I den övre grafen (a) visas det approximerade generella felet (grönt) samt träningsfelet (rött) för nätverk där antalet neuroner varierades mellan 1 och 581 med ett test per 20 neuroner. Vi kan antyda ett lokalt minimum hos träningsfelet vid ungefär 50 neuroner. Hos det generella felet syns dock inga tydliga extrempunkter. I den undre grafen (b) syns träning- och generaliseringsfelet, denna gång för nätverk med antalet neuroner mellan 1 och 100 med ett test per neuron. Även här kan vi antyda ett lokalt minimum mellan 40 och 70 neuroner. De till synes slumpmässiga svängningarna ser även ut ha mindre amplitud inom detta intervall. För det generella felet syns ingen antydning om några minimum.

I figur 12 syns det generella felet samt träningsfelet som funktion av antal iterationer vid träning av nätverket med 50 neuroner i det gömda lagret. Träningsfelet har ett minimum efter ungefär 300-400 iterationer och det generella felet har ett minimum efter enbart cirka 50 iterationer.




(a) Ett test per 20 neuroner



(b) Ett test per neuron

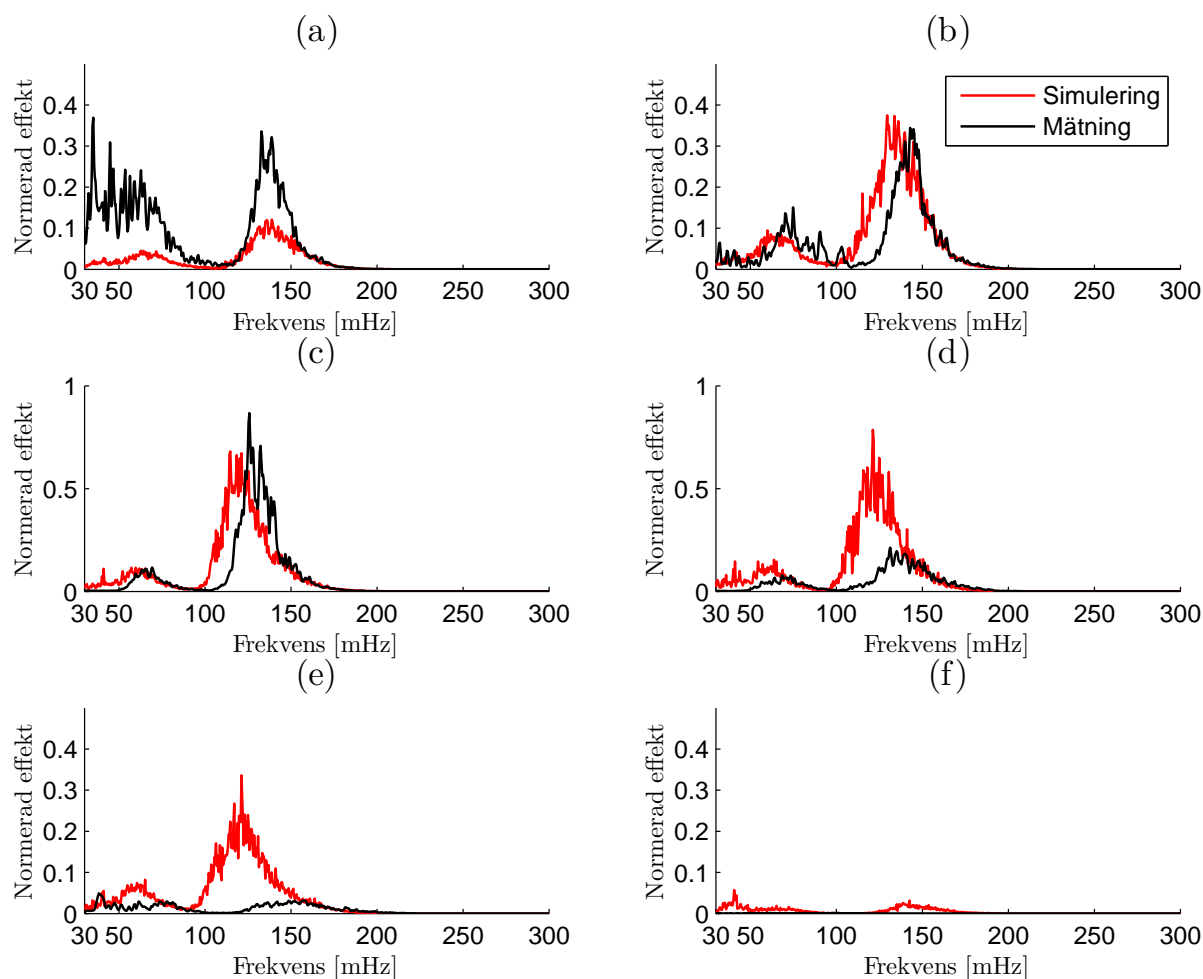
Figur 11: **Träningsfel och generellt fel för olika neuronantal.** Graferna visar hur träningsfelet (röd) och det generella felet (grön) ändras för olika antal neuroner i det dolda lagret i nätverket. Detta resultat har tagits fram genom att för varje neuronantal tränat nätverket genom 1000 iterationer och tagit ut det bästa tränings- och generella felet.




Figur 12: **Träningsfel och generellt fel mot antal iterationer.** *Grafen visar träningsfelet i rött och det generella felet i grönt. Det väntade resultatet vore att träningsfelet skulle vara generellt avtagande men som vi ser är så inte fallet. En anledning skulle kunna vara att felet har lokala minimum och de flertalet gånger helt enkelt byter vilka minimum de konvergerar mot.*

4.2 Prestandan hos det artificiella neurala nätverket

Graferna i detta stycke ämnar att jämföra det neurala nätverkets förutsägelser av effektspektrumet med de verkliga spektrumen för att möjliggöra en analys av hur väl nätverket presterar. Effektspektrum skapade av nätverket samt de verkliga effektspektrum från samma sextimmars-intervall tillhörande träningsdatan är plottade i figur 13. För högre toppar på de verkliga spektrumen (svart) är de relativt lika de simulerade spektrumen (röd) skapade av nätverket. För lägre toppar hos de verkliga spektrumen ökar skillnaden, både i höjd och position hos topparna. I figur 14 syns samma jämförelse med verifieringsdata, det vill säga data som inte använts för att träna nätverket. Skillnaden mellan de verkliga (svart) och de simulerade spektrumet (grön) är överlag större för verifieringsdatan än träningsdatan. Märkvärt är ett de simulerade spektrumen i de flesta fall genererar de två distinkta topparna som präglar de verkliga spektrumen.



Figur 13: **Jämförelse mellan uppmätta och simulerade spektrum för träningsdata.** Vi ser i figuren sex exempel på effektspektrum genererade från gravimeterdata (svart) och effektspektrum simulerade med det neurala nätverket (rött). Bilderna är ett urval ur mängden av träningsdata som har valts för att visa på hur nätverket hanterar olika typer av data. I figur (a) har simuleringen lyckats hitta topparna i effektspektrumet men underskattat amplituden. I resten av figurerna är de simulerade spektrumen förskjutna så att topparna har för låg frekvens. För data med hög amplitud i det uppmätta spektrumet (b, c) stämmer amplituden mycket bättre än de med låga amplituder (d, e, f). Detta gör att man troligen inte kan lita på att utseendet och amplituden på det simulerade spektrumet stämmer om amplituden är låg. Vidare kan man inte dra några exakta slutsatser från de frekvenstoppar ett genererat spektrum har då topparna inte ens överensstämmer med träningsdatan. Under förutsättningen att spektrumets amplitud är hög stämmer förhållandet mellan primär och sekundär mikroseismik.



Figur 14: **Jämförelse mellan uppmätta och simulerade spektrum för verifieringsdata.** Vi ser i figuren sex exempel på effektspektrum genererade från gravimeterdata (svart) och effektspektrum simulerade med det neurala nätverket (grönt). Bilderna är skapade med ett urval ur den så kallade verifieringsdatan, det vill säga data som inte användes för att träna nätverket. I figur (a, b, c) har de simulerade spektrumen i stora drag rätt form men en topp som är något för hög. I figur (e, d) överensstämmer topparnas frekvens med spektrumen från gravimeterdatan. Topparna i (d) stämmer dåligt vilket troligen beror på att signalen är mycket svag. Skillnaden i amplitud mellan de simulerade och uppmätta effektspektrumen varierar mycket vilket gör det svårt att dra slutsatser genom att jämföra absolut amplituder.

4.3 Frekvenstest med det artificiella neurala nätverket


Nedan följer resultaten från nätverkets konstruerade effektspektrum utgående från den konstgjorda vågdatan. I tabell 1 nedan visas de undersökte områden samt tillhörande figurnummer till figurerna där resultaten är presenterade.

Tabell 1: **Undersökta havsområden.** Tabellen visar de undersökta havsområdena samt figurnumret till deras konstruerade effektspektrum.

Undersökta områden:	Figur:
Biscayabukten	20, 25
Keltiska havet	21
Nordsjön	18
Norska havet	22, 25
Området söder om Grönland	17
Området runt Island	16
Stora delar av Europas kustområde	23
Västra djuphavet	19
Azorerna	15
Östra djuphavet	24

Vi ser effektspektrumen från området runt Azorerna, runt Island, söder om Grönland, på Nordsjön och på Västra djuphavet i figurerna 15, 16, 17, 18 och 19 respektive. Gemensamt för dessa områden är att spektrumen endast skiljer sig måttligt från referensdatan. Det finns dock en del saker som är anmärkningsvärda. Vi ser i spektrumen för Island och Grönland att vid 40 mHz sjunker mikroseismiken under referensvärdet. Spektrumet för Island har även en ganska stor topp över referensvärdet runt 95 mHz och för Grönlands ser vi att sekundärfrekvenstoppen sträcker sig omkring 10 mHz längre nedåt än referensspektrumet - till omkring 125 mHz. Eftersom effektspektrumen är logaritmerade är den bit som spektrumet för Azorerna sticker upp ovanför referensspektrumet inte försumbar. Det är ungefär 10 dB skillnad vilket motsvarar 10 gånger större seismiska vågamplituder.

Vidare tittar vi på spektrum där amplituden på mikroseismik är markant högre än referensspektrumet. Dessa kommer från konstgjord vågdata runt Biscayabukten, på Keltiska havet, på Norska havet och dessutom området innehållande större delar av Europas kust vilka vi ser respektive i figur 20, 21, 22 och 23. Gemensamt hos spektrumen för Biscaya och Norska havet är att de har ungefär samma form som referensspektrumet med skillnaden att de har omkring 10 dB större effekt för alla frekvenser samt att de har en väldigt stark topp runt 45 Hz. Vi ser att formen på spektrumet för området runt det Keltiska havet vid höga vågamplituder skiljer sig markant från samtliga övriga. Det har relativt de andra väldigt hög effekt i intervallet 90-130 mHz. Det är dessutom unikt i det avseende att det förändras kraftigt mellan våghöjderna. Det har sin pik vid 100 mHz. Vi




Figur 15: **Konstruerat spektrum för vågor runt Azorerna.** Bilden visar två spektrum simulerade av vårt artificiella neurala nätverk. Indatan är konstruerad och är vågdata för en lugn referensdag där våghöjden har tilldelats värdena 7 m respektive 14 m i ett område runt ögruppen Azorerna, se figur 8. Bilden visar även spektrumet för referensdagen. De simulerade spektrumerna är till formen väldigt lika referensdagen men de har en amplitud som är omkring 8 dB högre och topp på runt 45 mHz. Att det simulerade spektrumet är likt referensdagen tyder på att området kring Azorerna inte har stor inverkan på mikroseismiken i Onsala.


ser mycket tydligt på spektrumet för Europa att det är en superposition av spektrumerna från Keltiska havet, Biscayabukten och eller Norska havet. Vi ser både de förhöjda värdena, piken runt 45 mHz och den stora effektökningen i intervallet 90-130 mHz vid höga våghöjder.

I figur 25 visas spektrumerna från Biscayabukten och Norska havet och vi ser att sekundärfrekvenstopparna skiljer sig lite sinsemellan. Biscaya får toppar vid cirka 140-145 mHz medan Norska havet får sina toppar vid cirka 130-135 mHz.


Till slut tittar vi på spektrumet från konstruerade vågor på östra djuphavet som vi ser i figur 24. I frekvensområdet från 125-150 mHz är effekten är större än för referensspektrumet. Märkvärdt är även den blir väldigt liten för höga frekvenser. En tendens som den delar med det andra djuphavs området, västra djuphavet, se figur 24.




Figur 16: **Konstruerat spektrum vågor runt Island.** Bilden visar två spektrum simulerade av vårt artificiella neurala nätverk. Indatan är konstruerad och är vågdata för en lugn referensdag där våghöjden har tilldelats värdena 7 m respektive 14 m i ett område runt Island, se figur 8. Bilden visar även spektrumet för referensdagen. De simulerade spektrumen överensstämmer väl med referensspektrumet förutom att de är lite lägre vid låga frekvenser. Anledningen är antagligen någon form av felträning av nätverket. Eftersom höga vågor vid Island ger upphov till så lite mikroseismik kan det av en slump varit så att träningsdatan haft låg primärmikroseismik när det har varit höga vågor vid Island och nätverket har då tränat in detta samband. Vi ser även en skarp topp omkring 90-95 mHz vilket tyder på en tydlig resonans för det frekvensområdet.




Figur 17: **Konstruerat spektrum för vågor söder om Grönland.** Bilden visar två spektrum simulerade av vårt artificiella neurala nätverk. Indatan är konstruerad och är vågdata för en lugn referensdag där våghöjden har tilldelats värdena 7 m respektive 14 m i ett område söder om Grönland, se figur 8. Bilden visar även spektrumet för referensdagen. De simulerade spektrummen är nästan identiska med referensspektrumet. Vi ser dock att de simulerade spektrummen har sina sekundärfrekvenstoppar för något lägre frekvenser. Vi ser dock i figur 14 att vårt artificiella neurala nätverk inte hittar frekvenstopparna särdeles precist så denna förskjutning kan försummas.



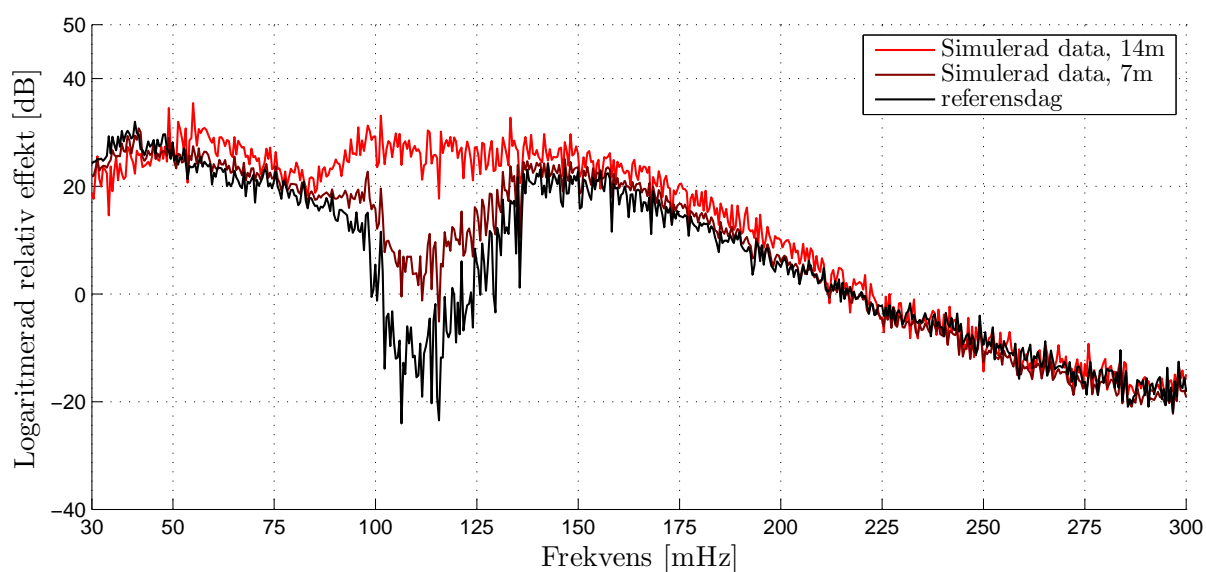
Figur 18: **Konstruerat spektrum för vågor på Nordsjön.** Bilden visar två spektrum simulerade av vårt artificiella neurala nätverk. Indatan är konstruerad och är vågdata för en lugn referensdag där våghöjden har tilldelats värdena 7 m respektive 14 m på Nordsjön, se figur 8. Bilden visar även spektrumet för referensdagen. De simulerade spektrumen är näst intill identiska med referensspektrumet. Detta är märkligt ty om vi tittar på karta över mikroiseismikgeneration, figur 26, så ser det ut som att nordsjön ska ge ett stort bidrag till den uppmätta mikroiseismiken. En förklaring skulle kunna vara att höga vågor i Kattegatt, vilket ingår Nordsjöområdet har en dämpande inverkan på spektrumet. Detta skulle kunna förklaras med att det näst intill aldrig förekommer så höga vågor i detta området så nätverket klarar inte av att hantera det.




Figur 19: **Konstruerat spektrum för vågor på västra djuphavet.** Bilden visar två spektrum simulerade av vårt artificiella neurala nätverk. Indatan är konstruerad och är vågdata för en lugn referensdag där våghöjden har tilldelats värdena 7 m respektive 14 m på västra djuphavet, se figur 8. Bilden visar även spektrumet för referensdagen. De simulerade spektrummen liknar referensspektrumet för höga amplituder men för frekvenser över 200 mHz avviker det markant. I detta frekvensområde är signalen väldigt låg och den här avvikelser kan tyckas försumbar men eftersom att gravimeterns inbyggda låpassfilter sänker amplituden på den här signalen med flera storleksordningar är det möjligt att avvikelser är av intresse. Det som framförallt är märkvärdt är att samma tendenser finns att se i det simulerade spektrummen för i östra djuphavet, se figur 24.




Figur 20: **Konstruerat spektrum för vågor i området runt Biscayabukten.** Bilden visar två spektrum simulerade av vårt artificiella neurala nätverk. Indatan är konstruerad och är vågdata för en lugn referensdag där våghöjden har tilldelats värdena 7 m respektive 14 m i ett område runt Biscayabukten, se figur 8. Bilden visar även spektrumet för referensdagen. Det genererade spektrumet med 14 meter våghöjd har mycket större amplitud än referensdagen vid alla frekvenser. Detta resultat är väntat med tanke på att Biscayabukten både är omgiven av kuster och överlappar kontinentalsockeln (se figur 9)




Figur 21: **Konstruerat spektrum för vågor på det Keltiska havet.** Bilden visar två spektrum simulerade av vårt artificiella neurala nätverk. Indatan är konstruerad och är vågdata för en lugn referensdag där våghöjden har tilldelats värdena 7 m respektive 14 m på Keltiska havet, se figur 8. Bilden visar även referensdagen. Det simulerade spektrumet för Keltiska havet skiljer sig på många sätt från de övriga simulerade spektrumet. De har en väldigt stark effekt i frekvensområdet 100-125 mHz och skiljer sig dessutom väldigt mycket i form och amplitud för de två olika våghöjderna.




Figur 22: **Konstruerat spektrum för vågor på Norska havet.** Bilden visar två spektrum simulerade av vårt artificiella neurala nätverk. Indatan är konstruerad och är vågdata för en lugn referensdag där våghöjden har tilldelats värdena 7 m respektive 14 m på Norska havet, se figur 8. Bilden visar även spektrumet för referensdagen. Det tydligaste resultatet är att det Norska havet har stor inverkan i vår simulering då effekten ökar för alla frekvenser. Effekten inom intervallet 100 mHz till 125 mHz ökar med med 30 dB. Detta frekvensintervall utmärker sig också i att formen på brusets är i stort sett samma för både simuleringen och referensdagen bortsett från att effekten höjts. Eftersom formen på brusets är bevarad även om effekten höjs finns det en stark korrelation mellan Norska havet och mikroseismik med frekvens runt 100 mHz till 125 mHz.




Figur 23: **Konstruerat spektrum för vågor över större delar av Europas kust.** Bilden visar två spektrum simulerade av vårt artificiella neurala nätverk. Indatan är konstruerad och är vågdata för en lugn referensdag där våghöjden har tilldelats värdena 7 m respektive 14 m i ett område som täcker stora delar av Europas kust, se figur 8. Bilden visar även spektrumet för referensdagen. Det syns väldigt tydligt de simulerade spektrumerna här är en superposition av delområdena Nordiska havet, området kring Biscayabukten och Keltiska havet, se figur 18, 20 och 21 respektive.



Figur 24: **Konstruerat spektrum för vågor på östra djuphavet.** Bilden visar två spektrum simulerade av vårt artificiella neurala nätverk. Indatan är konstruerad och är vågdata för en lugn referensdag där våghöjden har tilldelats värdena 7 m respektive 14 m i ett område runt östra djuphavet, se figur 8. Bilden visar även spektrumet för referensdagen. De simulerade spektrumen liknar referensspektrumet för höga amplituder men för frekvenser över 200 mHz avviker det markant. I detta frekvensområde är signalen väldigt låg och den här avvikelserna kan tyckas försumbar men eftersom att gravimeterns inbyggda lågpasfilter sänker amplituden på den här signalen med flera storleksordningar är det möjligt att avvikelserna är av intresse. Det som framförallt är märkvärdt är att samma tendenser finns att se i spektrumet för västra djuphavet, se figur 19. Notera även amplituden är förhöjd för sekundärtoppen medan den är samma som referensspektrumet för primärtoppen. Detta stämmer väl överens med teorier om att sekundär mikroseismik uppkommer på djupt vatten.



Figur 25: **Konstruerat spektrum för vågor på Norska havet och runt Biscayabukten** Bilden visar två spektrum simulerade av vårt artificiella neurala nätverk. Indatan är konstruerad och är vågdata för en lugn referensdag där våghöjden har tilldelats värdet 14 m i ett område runt Biscayabukten respektive på Norska havet, se figur 8. Bilden visar även spektrumet för referensdagen. Här är de riktiga signalerna uppritade med prickar och de heldragna linjerna är slätade splines för att lättare se signalerna utseende. Notera att de simulerade spektrumen är väldigt lika vilket är intressant då det är två områden med liknande förhållanden. Båda två har en kust ut mot Atlanten och havet blir djupt väldigt snabbt ifrån kusten.



Figur 26: **Karta över mikroseismikgeneration.** Vi har konstruerat vågdata där vi på den lugna referensdagen höjt våghöjden i ett 9 kvadratgrader stort område. Detta området har vi satt som indata till det tränade nätverket och sedan summerat alla datapunkter i spektrumet som nätverket ger ut. Det summerade värdet har logaritmerats och visas i figuren som värdet för mittpunkten av den 9-rutiga fyrkanten. Detta fungerar lite som nätverkets överföringsfunktion mellan våghöjdsdata och den totala mikroseismiken. Vi ser att mycket mikroseismik bildas i Norska havet och Biscayabukten men även på hela kontinentalsockeln, jämför med havsdjupet i figur 9. Märkvärt är även att mer mikroseismik bildas på de djupare områdena på båda sidorna om kontinentalryggen än runt Azorerna vilka ligger vid det mörkblåa området vid mittens av bildens undre kant.

4.4 Karta över mikroseismikgeneration på Atlanten

För att studera olika delar av Atlantens påverkan på mikroseismikgenerationen testade vi mindre områden än i frekvenstestet ovan men kontinuerligt över hela Atlanten. Vi ser att mikroseismikgenerationen har sina maxima vid Biscayabukten och Norska havet men hela kontinentalsockeln ser ut att generera mycket mikroseismik, jämför med havsdjupet i figur 9. Dessutom genereras det även mikroseismik längs Nordamerikas kust.

5 Diskussion

Resultatet stämmer ganska väl överens med det förväntade enligt teorin. Artificiella neurala nätverk tycks vara en bra metod för att modellera sambandet men det verkar krävas fortsatta undersökningar och ta hänsyn till en större mängd faktorer.

5.1 Antal neuroner och iterationer

I figur 11 syns det minsta generella felet samt det minsta träningsfelet för varje nätverk som funktion av antalet neuroner. Träningsfelet minskar när antalet neuroner ökar precis som förväntat enligt figur 3. Det generella felet varierar däremot slumpartat kring ett konstant värde en aning större än träningsfelet. Vi ser att träningsfelet möjligtvis har ett litet lokalt minimum runt 50-65 neuroner. Här har de slumpmässiga svängningarna lägre amplitud för träningsfelet än övrigt antal neuroner. Det generella felet har inga tydliga minima vilket medför en svårighet i att kunna avgöra vilket antal neuroner som är lämpligast. Vi kan argumentera för att träningsmängden är tillräckligt stor för att det ska krävas många fler neuroner för att nätverket skall överträna. Därför blir det rimligt att anta att det lämpligaste antalet neuroner är det antal då träningsfelet är minimerat. Trots att det är svårt att backa upp detta påstående när vi inte har konkreta bevis för att nätverket inte övertränar valdes antalet neuroner i det dolda lagret till 50 stycken.

Nätverket med 50 neuroner tränades sedan genom upp till 10 000 träningsiterationer för att undersöka träningsfelets och det generella felets möjlighet till att minskas ytterligare. I figur 12 visas tränings- och generaliseringsfelet som funktion av antalet iterationer för nätverket med 50 neuroner. Generaliseringsfelet har sitt minimum efter ungefär 50 iterationer. Av denna anledning valde vi att träna det slutgiltiga nätverket med 50 träningsiterationer.

Överlag minskar träningsfelet fram till 350-400 iterationer. Det ökar sedan snabbt för att falla ner på ett litet värde. Detta beteende har troligtvis sin grund i strukturen av träningsalgoritmen visad i ekvation (16) och (17). Absolutbeloppet av uppdateringsvärdet $\Delta_{ij}^{(t)}$ ökar vid varje iteration så länge den partiella derivatan $\frac{\partial E}{\partial \omega_{ij}^{(t)}}$ inte byter tecken från föregående iteration. Detta medför att förändringen av vikterna, så länge ett minimum inte passeras, bygger upp ett slags moment och kan passera långt förbi ett minimum. Detta kan medföra att felet byter minimum som det konvergerar mot.

5.2 Samband mellan våghöjd och mikroseismik

Vi kan se i figurerna 17, 18 och 19 att spektrumen skiljer sig mycket lite mot referensdagen vilket tyder på att dessa områden ger upphov till väldigt lite mikroseismik. I en del fall, Nordsjön och Västra djuphavet, har spektrumen lägre värden för större vågor. Det är orimligt att ett område ger upphov till negativ effekt, det tyder snarare på att nätverket är övertränat och att dessa punkter har fått en svag men negativ korrelation mot spektrumet

vid minimering av nätverkets fel. Det är möjligt att vi har en datamängd där det inte förekommer att dessa områden har starka vågor och därmed en stark påverkan vilket skulle kunna göra att nätverket inte vet hur det ska hantera sådant. Detta skulle kunna bero på att vi har ett problem i hur vi väljer data eller sorterar bort jordbävningar men det skulle också kunna bero på att dessa områden helt enkelt inte ger upphov till mikroseismik. Att dessa områden inte ger upphov till mikroseismik skulle motsäga Kedar som säger att havet utanför Grönland ofta har att två vågfronter möts och därmed bör ge upphov till mycket mikroseismik [7].

Områden nära kusten verkar ha ganska lika spektrum vilket går att se av figur 25. Detta stämmer ganska väl överens med dagens teori att mikroseismik väntas uppkomma i förhållandevis grundt vatten [10] [13] [14]. Eftersom vi inte tar hänsyn till vågriktningen finns risk att stormar i djuphav inte ger utslag i våra simulerade spektrum eftersom de ger effekt på effektspektrumet på ett för nätverket slumpmässigt sätt eftersom den inte vet om vågorna möts. Vid stormar närmare kusten krävs det inte att stormar möts för att de ska ge utslag i spektrumet och därmed bör nätverket mycket enklare klara av att korrelera dessa. Detta skulle innebära att det är vid de primära frekvenserna utslagen bör synas och det är mycket riktigt att det framför allt vid frekvenserna runt 50 mHz är där de stora skillnaderna syns. De har dock också klart starkare utslag vid dubbla frekvenser jämfört med referensdagen om än mindre skillnad än vid de primära. På grundare vatten skulle detta stämma bra överens med teorierna om att evanescenta vågor skulle ge upphov till sekundär mikroseismik [15] [11] [16]. En annan möjlig förklaring skulle kunna ha att göra med att båda dessa områden dessutom ligger precis kontinentalsocklarna vilket syns i figur 9 och leder till plötsligt och kraftigt minskat havsdjup. När vågor går från djupt till grundare vatten så minskar hastigheten samtidigt som amplituden ökar för att bibehålla vågens energi [25]. Detta skulle kunna leda till att vågor på det djupa sidan av kontinentalsockeln leder till stora vågor närmare kusten vilket skulle leda till stort utslag av mikroseismik. Det skulle kanske också kunna finnas ett samband mellan socklarna och vågornas riktning vilket skulle öka sannolikheten för möte mellan vågfronter vilket i så fall skulle spela roll.

Norska havet utmärkte sig när vi använde konstgjord data i det att formen på det brus som fanns i spektrumet för referensdagen bevarades när effekten höjdes. I figur 22 har bruset mellan 100 mHz och 125 mHz stora likheter trots att man höjt effekten med tiotals decibel. För att bruset ska kunna bevaras på detta sätt måste varje frekvens inom intervallet vara korrelerat mot det testade området. Detta tyder på att området utanför Norge är korrelerat mot sekundär mikroseismik.

De starkaste utslagen på totala effekten i mikroseismiken verkar vara ganska starkt kopplade till avståndet till Onsala med stor effekt i delar av Nordsjön och Norska havet vilket syns tydligt i figur 26. Detta är dock antagligen en följd av att havsområdet som är relativt nära Onsala både är kustnära och har lågt havsdjup. Enligt Longuet-Higgins teorier [3] så avtar amplituden med roten ur avståndet vilket i stort sett borde vara försumbart eftersom spektrummen skiljer sig flera storleksordningar sinsemellan. Det är

dock märkligt att kartan över mikroseismikgenerationen, figur 26, talar för att det ska vara hög mikroseismikgeneration i Nordsjön medan det konstruerade spektrumet för vågor på Nordsjön, figur 18, tyder på att det knappt ger upphov till någon mikroseismik alls. Detta skulle kunna förklaras med Nordsjöområdet innehåller Skagerrack och Kattegatt vilka skulle kunna ha en dämpande effekt på mikroseismikgenerationen i det artificiella neurala nätverket. Detta är uppenbarligen fel men det är inte så konstigt att nätverket misslyckas då den inte fått träna på vågdata med så höga vågor som vi simulerar med i detta område. Rekordet för våghöjd utanför Sveriges kust är till exempel 8.0 m [26].

Det ser även ut som om det är de primära vågorna som är mest märkbara eftersom det är nära land de flesta områden med högre utslag befinner sig. Detta skulle dock även kunna härröra från andra typer av strömmar som finns nära landområden som är mer sannolika att ge mötande vågfronter. Här är dock väldigt viktigt att komma ihåg att det inbyggda lågpasfiltret i gravimetern reducerar effekten från de höga frekvenserna med omkring två storleksordningar vilket medför att den primära mikroseismiken ger betydligt större utslag i alla figurer i rapporten. De ändrar dock inte resultaten på annat sätt än att relationen mellan den primära och sekundära mikroseismiken är skalad med omkring en faktor hundra. Det är till och med så att filtret har hjälpt oss ty det hade varit väldigt svårt att studera primär mikroseismik utan denna skalning.

5.3 Felkällor

Eftersom mikroseismik är ett såpass outforskat område finns det processer och faktorer vars påverkan inte är känd vilket kan leda till störningar. Det neurala nätverket kan bara ta hänsyn till saker som den får med i sin in- och utdata. Den klarar exempelvis av att ta hänsyn till havsdjup i beräkningarna eftersom den inte varierar med tiden och att varje indata svarar mot samma plats varje gång. Däremot klarar den inte av att ta hänsyn till exempelvis vilka riktningar vågorna rör sig i och vilka områden som har isbildning eftersom den datan varierar med tid och är för nätverket okänd, båda saker som enligt tidigare studier har påverkan på mikroseismiken [3][7].

En del av de faktorer som vi valt att inte studera är av geografisk karaktär så som till exempel underlaget på havsbotten. Dessa tar nätverket hänsyn till eftersom det korrelerar utslaget på gravimetern mot våghöjd på geografiska platser, det vill säga om det till exempel skulle ligga en hård berggrund i Biscayabukten som skulle vara fördelaktig för uppkomsten av mikroseismik skulle nätverket proportionellt skala upp mikroseismiken för vågor där.

5.3.1 Neurala nätverket

En annan viktig felkälla är vårt neurala nätverk. Det är visserligen väntat att nätverket inte ger full konvergens men det innebär också en osäkerhet, att nätverket bara lyckas beskriva sambandet till viss del vilket medför risk för att de simulerade effektspektrumen inte ser ut som de borde. Eftersom nätverken försöker minimera felet i absoluta tal så

innebär det att det framför allt tränar mot stora toppar och risk för att den övertränar mot dessa, detta är framför allt en risk med jordbävningar som smitit förbi filtret och kan ge upphov till kraftiga sidlober. Detta gör att de inte bör beaktas i detalj utan snarare bör tittas på i sin helhet. Att det dessutom är svårt att avgöra vilket antal neuroner som är det optimala gör att de felet vi hade när vi simulerade spektrum inte nödvändigtvis var det bästa. Detta gäller speciellt eftersom felet dessutom ökade efter ett antal iterationer tyder på att det eventuellt är ett annat minimum än det det först konvergerar mot. Detta skulle i sin tur kunna innebära att det finns andra extrempunkter som vi inte hittar och som skulle kunna vara bättre. Detta verkar dock relativt osannolikt då trots att vi startade med olika vikter i det neurala nätverket nästan alltid itererade på nästintill identiskt sätt.

5.3.2 Effektspektrum

Effektspektrumet i sig kan också vara en källa till fel, vi har hittat flertalet buggar under processens gång och det går aldrig att utesluta att det inte fortfarande skulle finnas några. Detta borde dock inte störa korrelationen nämnvärt då den bara försöker efterlikna spektrumet som bildats, det skulle dock innebära att de simulerade spektrummen blir fel på samma sätt som de beräknade. Däremot borde undersökningar om hur mycket effekt det finns för olika områden inte beröras alltför mycket då spektrumet i huvudsak är korrekt då det ger rimliga utvärden.

5.3.3 Hantering av vågdata

En annan källa till fel är att vi inte tagit hänsyn till att vi använt oss av en kvirektangulär projektion när vi hanterat vår vågdata. Det innebär att avståndet mellan två longituder projiceras samma oavsett latitud. Detta leder till att det uppstår ett horisontellt skalningsfel för avståndet mellan två longituder och det faktiska avståndet som ges av

$$\delta = \frac{1}{\cos \phi} \quad (25)$$

där ϕ är latituden. Området vår studie syftar till sträcker sig mellan N35° - N70° vilket betyder att den maximala relativa skalningsfelet blir

$$\frac{\cos 35^\circ}{\cos 70^\circ} \approx 2,395. \quad (26)$$

Detta innebär att om en storm som befinner sig vid N70° av vårt område kommer att täcka 2,395 gånger fler zoner än om den befunnit sig vid N35°. Felet kommer att påverka hur det neurala nätverket uppfattar två identiska stormar på olika latituder. Eftersom att zoner i områdets övre del motsvara mindre yta kommer nätverket att uppfatta dessa zoners inverkan som svagare. I figur 26 visas varje zons simulerade, totala inverkan på mikroseismiken och det finns inget klart samband mellan intensitet och longitud. Bidraget från felet borde alltså vara mindre bidraget från genererad mikroseismik.

Ytterligare en felkälla är att tidsupplösningen på vågdatan vi använder inte är särskilt hög utan vi har bara data för var sjätte timme. Visserligen rör sig inte stormar särskilt fort och är dessutom inte särskilt lokala vilket gör att effekterna i en punkt inte förändras särskilt snabbt men det blir ändå en liten skillnad. Vi har dessutom av praktiska skäl valt att jämföra varje vågdata mot effektspektrumet för kommande sextimmars period, eftersom mikroseismiken är att betrakta som omedelbar i denna tidsskala så hade det kanske blivit en bättre uppskattning att jämföra vågdata med effektspektrum för \pm tre timmar istället.

5.4 Fortsatta studier

Resultaten från detta arbete tyder på att artificiella neurala nätverk har en stor potential att kunna återskapa sambanden mellan havsvågor och mikroseismik. Vid fortsatt arbete inom detta område finns en mängd aspekter att undersöka vidare samt förbättra. Neurala nätverk har större möjlighet att finna samband och är dessutom svårare att överträna vid ökad träningsmängd. En större träningsmängd där då ett bredare utbud av typer av vågdata ingår är därför en förbättring. Eftersom det inte enbart är havsvågornas höjd och geografisk position som påverkar mikroseismiken är det neurala nätverket i detta arbete mycket begränsat. Att inkludera vågornas riktning i indatan till nätverket skulle medföra möjlighet för nätverket att skilja på primär och sekundär mikroseismik inom samma område. Även en mer noggrann filtrering av jordskalv i gravimeterdatan bidrar till bättre prestation från nätverket.

Vid fortsatta studier bör även en mer grundlig analys utföras vid optimering av antal lager samt neuroner i nätverket. Att göra en bättre uppskattning av det generella felet genom exempelvis en större testmängd är en god start.

Det finns även intresse att följa hur mikroseismiken påverkas i takt med att klimatet förändras. Eftersom att det finns arkiv med seismisk data som sträcker sig längre bakåt än data för havstemperaturer. Eftersom mikroseismiken är relaterad till den totala energin i haven och därmed också vågorna kan mikroseismiken bli en viktig måttstock för hur haven påverkas av klimatförändringarna [8].

6 Slutsats

Vår studie visar att det tycks vara möjligt att använda neurala nätverk för att modellera sambandet mellan havsvågor och mikroseismik. Vi finner dock att de faktorer vi tagit hänsyn till troligen inte är tillräckliga för att ge ett fullvärdigt samband. Det är troligt att om det neurala nätverket får kunskap om vågornas riktning så kommer en bra korrelation att kunna finnas. Våra resultat tyder på att uppmätt mikroseismik till stor del kommer ifrån området runt Europas kust och framför allt från Norska havet och Biscayabukten. Havet utanför Grönland tycks dock inte ha den stora påverkan på mikroseismik som visa tidigare teorier förutsagt. Detta tyder på att mikroseismik huvudsakligen uppkommer vid kustnära områden, i synnerhet områden där djupet ökar snabbt från kusten.

Referenser

- [1] A. Ben-Menahem, “A concise history of mainstream seismology: origins, legacy, and perspectives”, *Bulletin of the Seismological Society of America*, vol. 85, nr 4, s. 1202–1225, 1995.
- [2] J. Dewey och P. Byerly, “The early history of seismometry (to 1900)”, *Bulletin of the Seismological Society of America*, vol. 59, nr 1, s. 183–227, 1969.
- [3] M. Longuet-Higgins, “A theory of the origin of microseisms”, *Philosophical Transactions of the Royal Society of London. Series A, Mathematical and Physical Sciences*, vol. 243, nr 857, s. 1–35, 1950. DOI: 10.1098/rsta.1950.0012.
- [4] R. I. B. Cooper och M. S. Longuet-Higgins, “An experimental study of the pressure variations in standing water waves”, English, *Proceedings of the Royal Society of London. Series A, Mathematical and Physical Sciences*, vol. 206, nr 1086, pages, 1951, ISSN: 00804630.
- [5] T. Tanimoto, “Excitation of microseisms: views from the normal-mode approach”, *Geophysical Journal International*, vol. 194, nr 3, s. 1755–1759, 2013. DOI: 10.1093/gji/ggt185.
- [6] W. S. Sarle, *Sas faq*, <ftp://ftp.sas.com/pub/neural/FAQ3.html>, [Online; accessed 24-April-2014].
- [7] S. Kedar, M. Longuet-Higgins, F. Webb, N. Graham, R. Clayton och C. Jones, “The origin of deep ocean microseisms in the north atlantic ocean”, *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Science*, vol. 464, nr 2091, s. 777–793, 2008. DOI: 10.1098/rspa.2007.0277.
- [8] P. D. Bromirski, “Earth vibrations”, *Science*, vol. 324, nr 5930, s. 1026–1027, 2009. DOI: 10.1126/science.1171839.
- [9] L. I. Irwin Vigness E. W. Kammer; J. E. Dinger, “Sea swell and microseisms”, *Journal of Atmospheric Sciences*, vol. vol. 9, s. 443, 6 1952. DOI: 10.1175/1520-0469(1952)009<0443\<SSAM\>2.0.CO;2.
- [10] T. Tanimoto, “Excitation of normal modes by non-linear interaction of ocean waves”, *Geophysical Journal International*, vol. 168, nr 2, s. 571–582, 2007, ISSN: 1365-246X. DOI: 10.1111/j.1365-246X.2006.03240.x.
- [11] P. D. Bromirski, F. K. Duennebier och R. A. Stephen, “Mid-ocean microseisms”, *Geochemistry, Geophysics, Geosystems*, vol. 6, nr 4, 2005, ISSN: 1525-2027. DOI: 10.1029/2004GC000768.
- [12] K. Hasselmann, “A statistical analysis of the generation of microseisms”, *Reviews of Geophysics*, vol. 1, nr 2, s. 177–210, 1963, ISSN: 1944-9208. DOI: 10.1029/RG001i002p00177.

- [13] P. D. Bromirski, R. E. Flick och N. Graham, “Ocean wave height determined from inland seismometer data: implications for investigating wave climate changes in the ne pacific”, *Journal of Geophysical Research-Oceans*, vol. 104, nr C9, s. 20 753–20 766, sept. 1999. DOI: 10.1029/1999jc900156.
- [14] G. Hillers, N. Graham, M. Campillo, S. Kedar, M. Landès och N. Shapiro, “Global oceanic microseism sources as seen by seismic arrays and predicted by wave action models”, *Geochemistry, Geophysics, Geosystems*, vol. 13, nr 1, 2012, ISSN: 1525-2027. DOI: 10.1029/2011GC003875.
- [15] C. S. Cox och D. C. Jacobs, “Cartesian diver observations of double frequency pressure fluctuations in the upper levels of the ocean”, *Geophysical Research Letters*, vol. 16, nr 8, s. 807–810, 1989, ISSN: 1944-8007. DOI: 10.1029/GL016i008p00807.
- [16] J. Traer, P. Gerstoft, P. D. Bromirski och P. M. Shearer, “Microseisms and hum from ocean surface gravity waves”, *Journal of Geophysical Research: Solid Earth*, vol. 117, nr B11, 2012, ISSN: 2156-2202. DOI: 10.1029/2012JB009550.
- [17] S. C. Webb, *The earth’s “hum” is driven by ocean waves over the continental shelves*, 2007. DOI: 10.1038/nature05536.
- [18] *Observatory superconducting gravimeter (osg)*, GWR intstruments, inc, 6264-D, Ferris square, San Diego, okt. 2011. URL: http://catalog.gwrinstruments.com/Asset/OSG_Dual_Brochure_Rev_1.0.pdf.
- [19] A. V. Oppenheim och R. W. Schaffer, *Digital Signal Processing*. Prentice–Hall, 1975.
- [20] Wikipedia, *Artificial neural network*, http://en.wikipedia.org/wiki/Artificial_neural_network, [Online; accessed 13-Februari-2014].
- [21] W. W. Hsieh och B. Tang, “Applying neural network models to prediction and data analysis in meteorology and oceanography”, English, *Bulletin of the American Meteorological Society*, vol. 79, nr 9, s. 1855–1870, 1998.
- [22] P. Burrell och B. Folarin, “The impact of neural networks in finance”, English, *Neural Computing & Applications*, vol. 6, nr 4, s. 193–200, 1997, ISSN: 0941-0643. DOI: 10.1007/BF01501506.
- [23] J. Sietsma och R. J. F. Dow, “Neural net pruning-why and how”, i *Neural Networks, 1988., IEEE International Conference on*, juli 1988, 325–333 vol.1. DOI: 10.1109/ICNN.1988.23864.
- [24] H. P. Hsu, *Schaum’s Outlines of Probability, Random Variables, and Random Processes*, Vol. 2, ser. Schaum’s Outline Series. New York: McGraw-Hill, 2011, ISBN: 978-0-07-163289-8.

-
- [25] M. Longuet-Higgins och R. Stewart, "Radiation stresses in water waves; a physical discussion, with applications", *Deep Sea Research*, vol. 11, nr 4, s. 529–562, 1964, ISSN: 0011-7471. DOI: [http://dx.doi.org/10.1016/0011-7471\(64\)90001-4](http://dx.doi.org/10.1016/0011-7471(64)90001-4).
- [26] SMHI, *Extrema vågor*. URL: <http://www.smhi.se/kunskapsbanken/oceanografi/extrema-vagor-1.3081> (hämtad 2014-05-19).