

Maskininlärningsmetoder för att analysera gravitationsvågor

Kandidatavhandling

Mårten Jern
2021



Innehållsförteckning

Definitioner.....	3
1 Inledning.....	4
2 Gravitationsvågor.....	5
2.1 Gravitationsvågor och elektromagnetisk strålning.....	5
2.2 Mätning av gravitationsvågor.....	6
3 Metoder för att upptäcka gravitationsvågor.....	7
3.1 Matchad filtrering.....	7
3.2 Slumpskogar.....	7
3.3 Neurala nätverk.....	9
3.4 Jämförelse mellan slumpskogar och neurala nätverk.....	13
4 Avslutning.....	13
5 Referenser.....	14

Definitioner

gravitationsvågor - även gravitationsstrålning, en typ av fysisk vågrörelse som uppkommer när kompakta massamlingar kröker rymdtiden kraftigt

neutronstjärna – en stjärna i sin livscykelns slutskede, då dess kvarvarande inre delar imploderar

pulsar – roterande neutronstjärna som genererar elektromagnetisk strålning och kan generera gravitationsstrålning

elektromagnetisk strålning – även elektromagnetiska vågor, den fysiska vågrörelse utgör t.ex. synligt ljus, radiovågor och röntgenstrålning och består av oskillerande magnetiska- och elektriska fält

supernova – en exploderande eller exploderad stjärna som bildas om en neutronstjärna har tillräckligt stor massa

matchad filtrering (eng. matched filtering) – en vanlig teknik för att upptäcka gravitationsvågor som använder sig av en mall för hur vågformen förväntas se ut

slumpskog (eng. random forest) – en algoritm som t.ex. används för att klassificera dataobjekt och ger som utdata ett medeltal av en uppsättning beslutsträds klassificering

beslutsträd (eng. decision tree) – en trädstruktur som delar upp datagrupper på basen av variabler som karaktäriserar dem och kan används för att klassificera data med okänd klassificering

neurala nätverk (eng. neural network) – en maskininlärningsalgoritm som är inspirerad av biologiska neurala nätverk och består av neuroner som linjärt manipulerar och skickar data mellan varandra och tillsammans bildar en icke-linjär funktion, används t.ex. för klassificeringsuppgifter

linjär funktion – funktion på formen $f(x) = ax + b$

icke-linjär funktion – funktion som inte är linjär, t.ex. $f(x) = e^x - 2x^2 + \sqrt{x}$

koherent – "i samma fas", används om vågrörelser

regression – en statistisk metod som på basen av kända datapunkter förutser okända datapunkter

träningssdata – en uppsättning data med känd klassificering som används för att "träna upp" en maskininlärningsalgoritm så att den kan klassificera ny data

sjunkgradient (eng. gradient descent) – metod som används för att hitta minimipunkten på en kurva

förlustfunktion (eng. loss function) – funktion som på basen av en uppsättning parametrer anger hur stor skillnaden är mellan en funktions värde och dess önskade värde

störning (eng. glitch) – en avvikande företeelse i ett mätresultat, som kan orsakas t.ex. av instrumentellt- eller miljöbrus

brus (eng. noise) – oönskat (vanligen) ljud, men även oönskade moment i andra former av mätningar, om man försöker mäta någonting vill man vanligen filtrera bort bruset

pik (eng. spike) – en spetsformade avvikelse i en kurva

bayesiansk inferens (eng. Bayesian inference) – metod som bestämmer sannolikheten för en hypotes på basen av relevant information

överanpassning (eng. overfitting) – ett fenomen som uppstår då man tränar upp en maskininlärningsalgoritm för en klassificerings- eller regressionsuppgift och algoritmen fäster för stor uppmärksamhet vid enskilda dataobjekt, så att de "med våld" passar in i modellen, detta påverkar klassificerings- eller regressionsförmågan negativt

1 Inledning

Förekomsten av gravitationsvågor förutsågs av Albert Einsteins allmänna relativitetsteori. Gravitationsvågor uppkommer när kompakta energisamlingar kröker rymdtiden kraftigt. När dessa samlingar ändrar form skapas en föränderlig krökning i rymdtiden, som framskrider genom rymden med ljusets hastighet. Detta kallas för gravitationsvågor. [1]

Den första mätningen av gravitationsvågor (se Fig. 1) gjordes 2015 av observatoriet Laser Interferometer Gravitational-Wave Observatory (LIGO) i USA. [2]

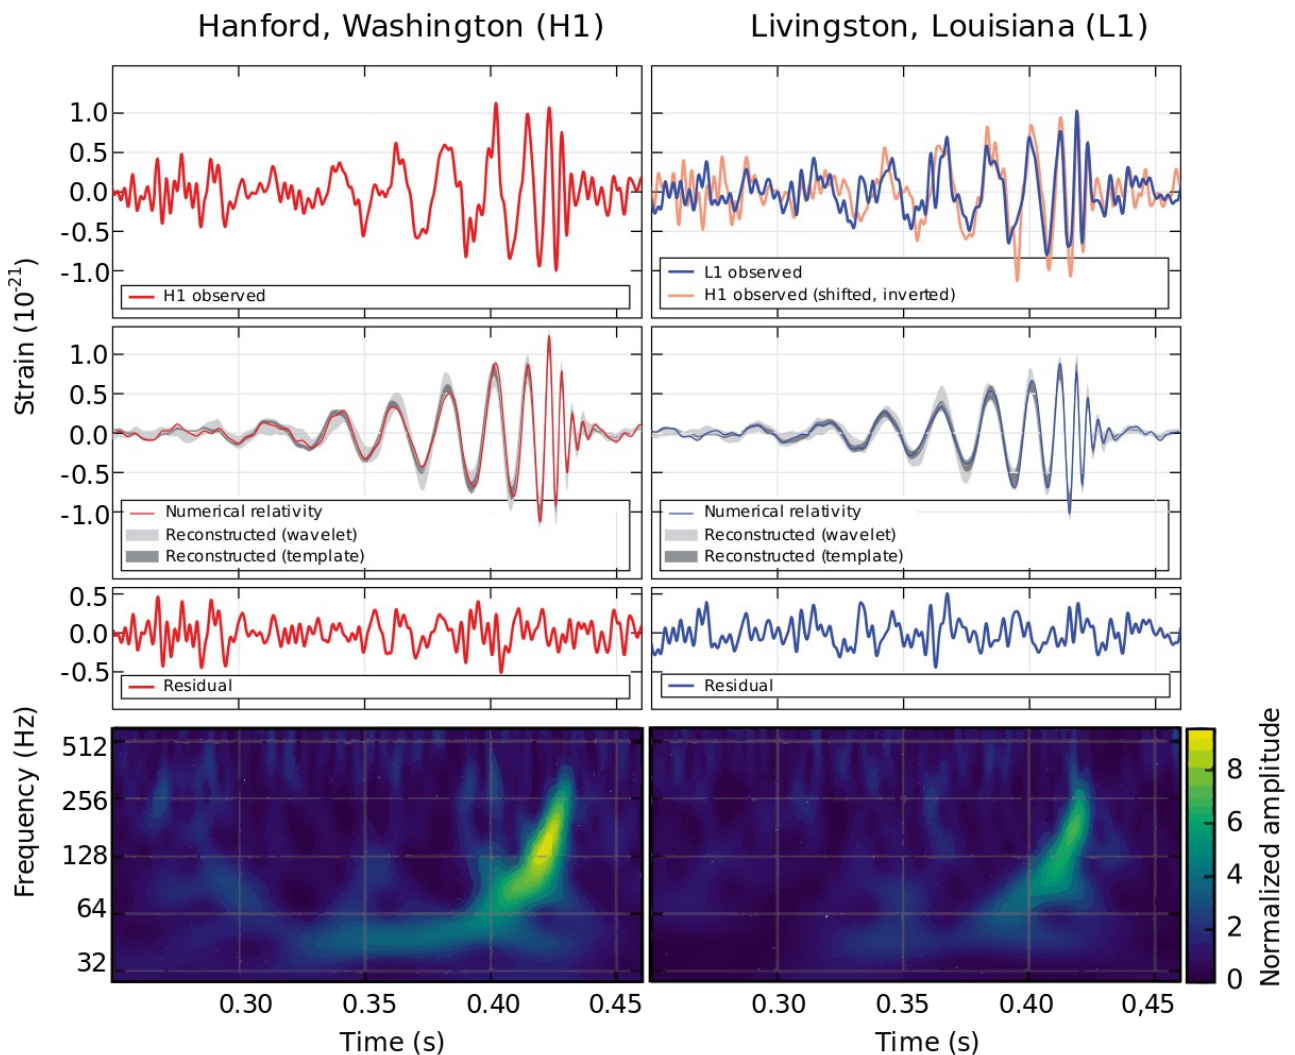


Fig. 1: Bilden visar grafer för den första gravitationsvågsupptäckten, som gjordes 14 september 2015 av LIGO-observatoriet, med detektorer i Hanford (vänster) och Livingston (höger). På första raden visas vad som uppmättes, på andra raden den förväntade mätningen på grund av en händelse från ett binärt system av svarta hål. På den tredje raden åskådliggörs skillnaden mellan den förväntade mätningen och den faktiska uppmätta kurvan. På sista raden visas en tids-frekvens-kurva för upptäckten, som visar att frekvensen stiger med tiden. [2]

Gravitationsvågor skiljer sig från elektromagnetiska vågor lika mycket som ljud skiljer sig från ljus. Det här betyder att andra fenomen och objekt i universum kan observeras då man mäter gravitationsstrålning, och man kan utforska universum med nya ögon. Elektromagnetisk strålning påverkas av materia, medan gravitationsstrålning knappt alls påverkas, vilket betyder att den information vi får från gravitationsstrålning är närmast oförvrängd. De källor till gravitationsstrålning som går att observera är till exempel kolliderande svarta hål, sammansmältande neutronstjärnor, exploderande stjärnor och kanske till och med universums uppkomst [3]. En rent praktisk orsak till att man vill mäta gravitationsvågor är att de hjälper oss att uppskatta Hubble-konstanten, som representerar hur snabbt universum expanderar. [4]

För närvarande använder man sig mest av en metod som heter matchad filtrering (eng. matched filtering, se Metoder för att upptäcka gravitationsvågor) för att upptäcka gravitationsvågor. Denna metod har dock visat sig vara beräkningsmässigt krävande, med en beräkningstid som är en funktion av detektorernas känslighet och antalet observatorier, vilka båda förväntas öka inom den närmaste tiden. [5]

Istället har man på sistone börjat använda sig av maskininlärningsmetoder för att analysera potentiella gravitationsvågssinglar. Dessa metoder är effektiva för att identifiera mönster i data. [6]

I den här avsnittet jämförs olika maskininlärningsmetoder för att upptäcka gravitationsvågor och undersöka om det är möjligt att klassificera data från gravitationsvågupptäckter på basen av vilken källa gravitationsvågorna härstammar från. De metoder som undersöks särskilt är slumpskogar (eng. random forest) och neurala nätverk (eng. neural networks), och dessa jämförs även med den konventionella metoden matchad filtrering.

2 Gravitationsvågor

2.1 Gravitationsvågor och elektromagnetisk strålning

Gravitationsvågor skiljer sig från elektromagnetisk strålning i flera hänseenden:

- Elektromagnetiska vågor består av ett oskillerande elektromagnetiskt fält, medan gravitationsvågor innebär att själva rymdtiden oskillerar.
- De elektromagnetiska vågor som förekommer i rymden är inkoherenta (har inte

samma fas) och härstammar från individuella elektroner, atomer eller molekyler, medan gravitationsvågor är koherenta och härstammar från rörelser i stora energi- eller massamlingar.

- Det är lättare att göra en bild av källan då man observerar elektromagnetisk strålning, eftersom våglängden är liten jämfört med källan. Gravitationsvågor däremot har en våglängd som ofta är större än källan, och då kan man inte på samma sätt göra en bild av källan. Dock förmedlar gravitationsvågor nog information om källan, se Metoder för att upptäcka gravitationsvågor.
- Elektromagnetiska vågor absorberas, sprids eller skingras lätt av materia. Gravitationsvågor å andra sidan påverkas knappt alls av materia.
- Elektromagnetisk strålning har en mycket högre frekvens, mellan 10^7 och 10^{27} Hz, medan gravitationsstrålning håller sig mellan 10^{-16} och 10^4 Hz.

[1]

2.2 Mätning av gravitationsvågor

Gravitationsvågor påverkar rymdtidens geometri. När man mäter gravitationsvågor i LIGO- och VIRGO-observatorierna har man två vinkelräta armar vars längd förändras när de kommer i kontakt med gravitationsvågor. Man mäter längdskillnaden mellan axlarna och får därmed information om gravitationsvågorna. Till exempel armarna i VIRGO-observatoriet är 3 km långa. I Fig. 2 åskådliggörs hur armarna påverkas av gravitationsvågor. [7]




Fig. 2: Bilden illustrerar hur armarna i en interferometer påverkas av gravitationsvågor. [8]

Gravitationsvågor med en frekvens på under 1 Hz är så gott som omöjliga att upptäcka från ett observatorium på Jorden, eftersom det finns en stor mängd brus, från dels fluktuerande Newtoniska gravitationsgradienter, och dels från Jordens vibrationer. Då är det enda alternativet att mäta gravitationsvågorna från rymden, vilket ESA (European Space Agency) planerar att göra med LISA (Laser Interferometer Space Antenna) från och med det tidiga 2030-talet. [9], [1]

De gravitationsvågor man lyckats upptäcka härstammar från binära svarta hål, binära neutronstjärnor och system bestående av en neutronstjärna och ett svart hål [6]. Andra källor är till exempel gravitationsvågsutbrott (eng. gravitational-wave burst). Gravitationsvågsutbrott är kortlivade signaler med okänd- eller delvis modellerad vågform. Möjliga källor till gravitationsvågsutbrott är kärnkollapsande supernovor (eng. core-collapse supernova), störningar i pulsarers rotation (en pulsar är en roterande neutronstjärna), neutronstjärnor som kollapsar till svarta hål, kosmiska stränguddar (eng. cosmic string cusp - mera om kosmiska strängar i [10]).

3 Metoder för att upptäcka gravitationsvågor

3.1 Matchad filtrering

En konventionell teknik för att upptäcka gravitationsvågor från kompakta binära sammansmältningar (eng. compact binary coalescence) är matchad filtrering, som antas vara det bästa linjära filtret för att extrahera en signal med känd form blandad med stationärt Gauss-brus. Matchad filtrering fungerar så att man multiplicerar utdatan från detektorerna med en tidsfunktion som kallas för mall (eng. template), och som beskriver den förväntade vågformen. Sedan integrerar man resultatfunktionen, och undersöker hur högt resultatet är. Det är högre om utdatan från detektorn härstammar från gravitationsvågor än om den härstammar från brus. [5]

3.2 Slumpskogar

Den första maskininlärningsmetoden vi undersöker i denna avhandling är slumpskogar (eng. random forest), som används främst för klassificerings- och regressionsuppgifter. **[källa]** En slumpskog består av en uppsättning beslutsträd (eng. decision tree). **[källa]** Noderna i ett beslutsträd representerar "variabler" (eng. characteristic), och grenarna representerar olika värden för dessa variabler. Grenarna delar upp (tränings-)dataobjekten i grupper beroende på objektens värden på

den variabel som föräldranoden (eng. parent node) representerar. Variablerna väljs på basen av vilken variabel som bäst delar upp träningsdataobjekten i de kategorier som ska bestämmas, alltså vilken variabel resulterar i att gruppuppdelningen medför flest "rätt klassificerade" dataobjekt. På nästa nivå (alltså barnnoderna (eng. child node)) upprepas uppdelningsprocessen, och man väljer den av de återstående variablerna som bäst delar upp den grupp som gått vidare till den aktuella noden. Detta upprepas till dess att alla objekt i en uppdelning är rätt klassificerade. I Fig. 3 visas hur uppdelningen går till. [11]

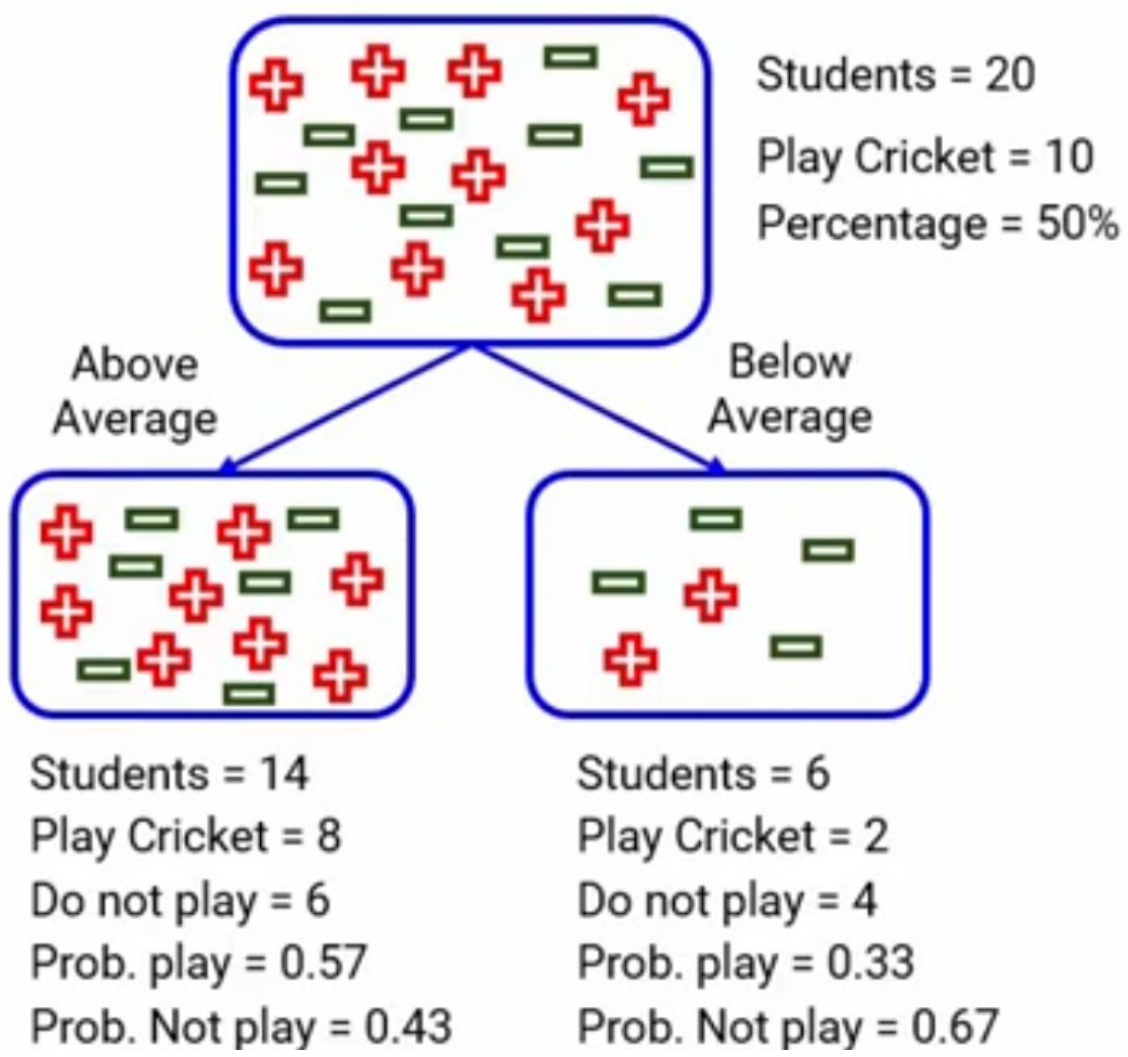


Fig. 3: Här ser vi hur ett beslutsträd delar upp studenter i klasserna "spelar cricket" och "spelar inte cricket" på basen av deras vitsord. Det är en uppdelning som bidrar med någonting, eftersom en majoritet av objekten (studenterna) är rätt klassificerade. Denna process upprepas nedåt i trädet till dess att en dylik uppdelning resulterar i en fullständigt korrekt klassificering. [12]

Nu kan man köra ett dataobjekt med okänd klassificering genom trädet, och på basen av värdena på

dess variabler traversera det. Beslutsträdets klassificering för objektet kan utläsas av vilken klassificering träningsdataobjekten i den nådda lövnoden har. I fallet med att upptäcka gravitationsstrålning finns bara två klassificeringar: gravitationsstrålning och icke-gravitationsstrålning.

I en slumpskog har man flera beslutsträd och variablerna som man delar träningsdataobjekten på basen av väljs utifrån en slumpmässig delmängd av alla variabler (som kvarstår) och man får därmed variation i träden. Dessutom görs klassificeringen i en slumpskog på basen av alla träd klassificering av dataobjektet [13]. Ett medelvärde beräknas och det är slumpskogens uppskattade klassificering av dataobjektet [14].

Man har på sistone undersökt närmare hur väl slumpskogar lämpar sig för att upptäcka gravitationsvågor från kompakta binära sammansmältningar. De vanligaste typerna av kompakta binära sammansmältningar är binära svarta hål, binära neutronstjärnor och binära system bestående av en neutronstjärna och ett svart hål. Man har kunnat visa att känsligheten för att upptäcka gravitationsvågor från binära svarta hål - med medelstor massa respektive massa i storlek med en stjärna - är ca 70-109% högre med slumpskogar än med matchad filtrering [6].

Ett verktyg som används för att bestämma parametrarna för en gravitationsvågskälla är LALInference. I verktyget används Bayesisk inferens (eng. Bayesian inference), som är en ganska långsam process och kan ta veckor att genomföra. Algoritmen RIFT, som baseras på antingen Gauss-processer eller slumpskogsregression, är ett betydligt snabbare verktyg som uppskattar sannolikheterna för parametrarna i Bayesisk inferens. [6]

Genom att bestämma parametrarna för en källa till gravitationsstrålning kan man bestämma källans typ, vilket är en av avhandlingens huvudfrågor.

3.3 Neurala nätverk

Den andra maskininlärningsmetoden som undersöks är neurala nätverk. Neurala nätverk är inspirerade av de biologiska neurala nätverk som förekommer hos djur. Ett artificiellt neuralt nätverk består av en uppsättning sammankopplade noder som kallas artificiella neuroner. Kopplingarna kallas för kanter (eng. edge), och över dessa skickas signaler mellan neuronerna. Signalerna utgörs av reella tal, och beräknas enligt en linjär funktion på basen av indata till

neuronerna. Neuronerna har så kallade vikter (eng. weight), som bestämmer styrkan i de signaler som skickas ut från neuronerna. Vikterna hör ihop med en specifik koppling till en annan neuron och uppdateras under inlärningsprocessen.

När man använder neurala nätverk måste man först träna upp dem. Detta gör man med hjälp av en uppsättning träningsdata. Klassificeringen av dessa är känd, och nätverket lär sig att identifiera karaktäristikerna för olika klassificeringar. Detta sker genom att nätverket matas med träningsdata och vikterna i neuronerna justeras enligt en träningsregel (eng. training rule). [15]

Träningsregeln för en neuron ser ut som följande:

1. Välj slumpartade vikter för kopplingarna.
2. Välj en indatavektor (eng. input vector) x från träningsdataobjekten.
3. Om neuronerna ger felaktig utdata uppdateras vikten enligt $\Delta w_i = d(x)x_i$, där w_i är vikten i fråga, $d(x)$ är önskat utdata, och x_i indata till neuronerna.
4. Om neuronerna ger önskat utdata uppdateras inte vikten.
5. Återgå till steg 2.

[15]

Metoden för att bestämma vikterna på ett optimalt sätt kallas för sjunkgradient (eng. gradient descent), och går ut på att minimera förlustfunktionen (eng. loss function), som anger hur långt ifrån det önskat utdata man ligger [16].

Under inlärningsprocessen används även en uppsättning valideringsdata, vars uppgift är att se till att inlärningsframskridet som önskat. För att till sist utvärdera hur väl nätverket klarar av sin uppgift använder man sig av testdata. Med denna undersöker man om klassificeringsförmågan fungerar som önskat. [17]

Inom ett neuralt nätverk finns det tre typer av enheter: indataenheter (eng. input unit), som tar in data från utsidan av nätverket, utdataenheter (eng. output unit), som förmedlar information till utsidan av nätverket, samt gömda enheter (eng. hidden unit), vars uppgift är att skicka data mellan enheter inuti nätverket. De gömda enheterna är vad som motsvaras av neuroner i ett biologiskt neuralt nätverk. [15], [16]

Indata till en enhet består av den faktiska signalen som tas emot, samt ett tillägg som beror på

enhetens bias.

Ett neuralt nätverk utgör samantaget en icke-linjär funktion (se Fig. 4), $h_{\theta}(x)$ - där θ består av uppsättningen parametrar för nätverket (vikterna för neuronerna och biasen) - som innehåller flera linjära funktioner med indata och utdata som skickas vidare till andra linjära funktioner.

θ_i , alltså parametrarna för nätverket, är vad som motsvaras av synapser i ett biologiskt neuralt nätverk. [16]




Fig. 4: Här ser man hur olika indata till neuronerna bearbetas och av noderna och tillsut resulterar i binär utdata, genom en icke-linjär process. [18]

Ett stort störningsmoment inom sökningen efter gravitationsvågor är detektorstörningar (eng. detector glitch). Dessa störningar orsakas av kortlivat miljö- och instrumentellt brus. De är icke-injära transienter som är kontinuerliga och icke-stationära. För att kunna skilja störningarna från gravitationsvågsdata gäller det att urskilja dem och klassificera dem i familjer.

Det har visat sig att konvolutionella neurala nätverk är väldigt bra på detta. De är designade för att att läsa ut egenskaper från t.ex. bilder för klassificeringssyften. En typ av bild man kan mata till neurala nätverk för att lära dem känna igen störningar är tid-frekvens-grafer. Exempel på störningar som uppträder i dylika grafer åskådliggörs i Fig 5. [6]

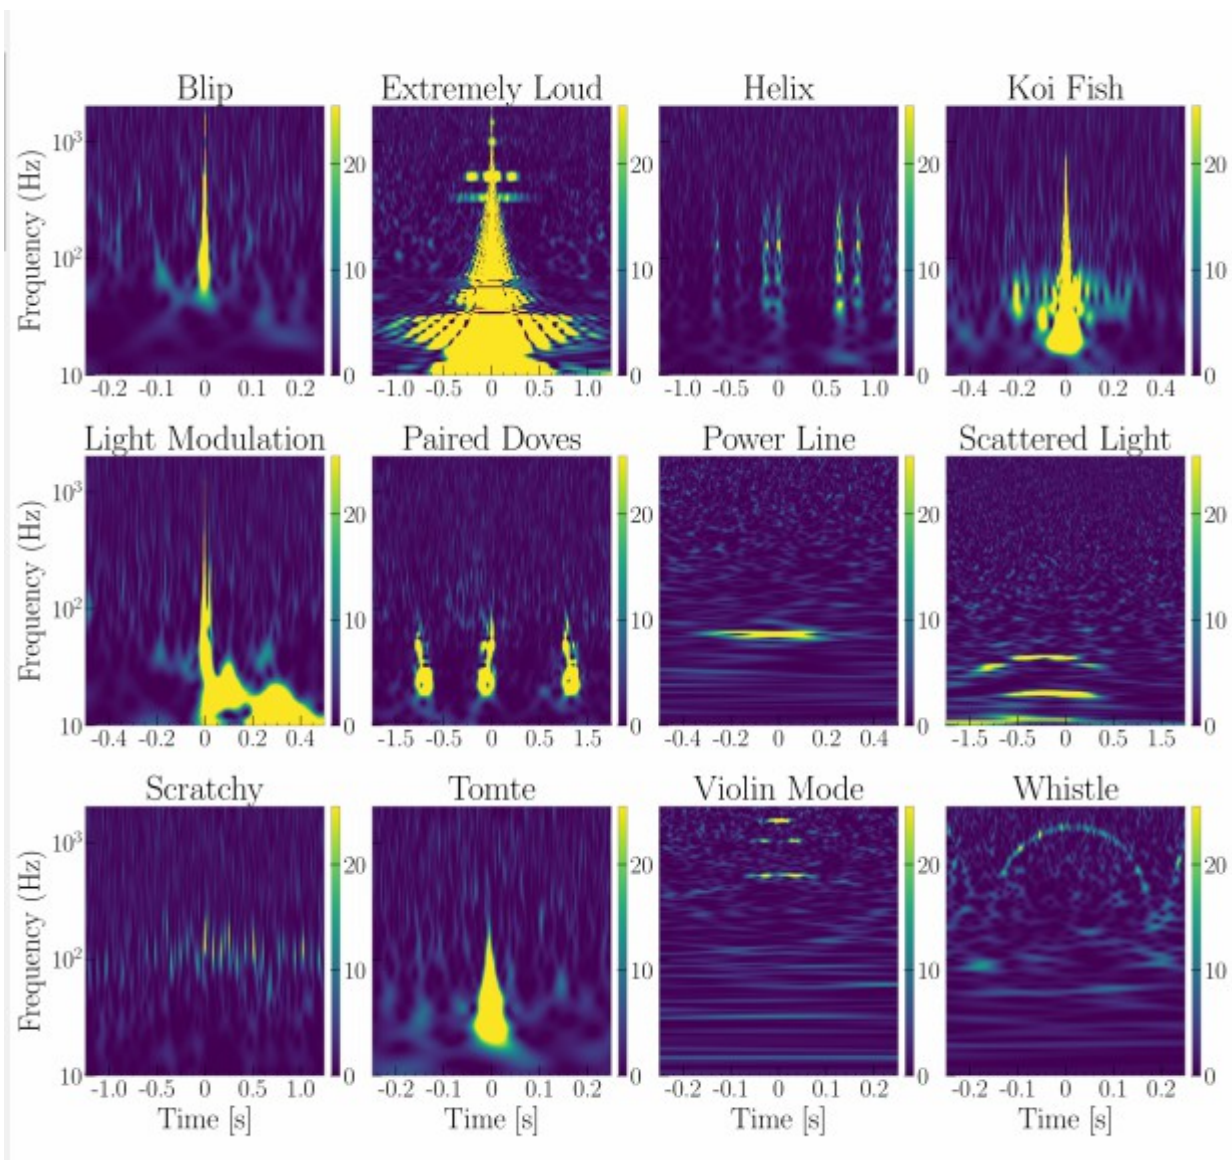


Fig. 5. Tids-frekvens-grafer som visar detektorstörningar som uppkommer då man söker efter gravitationsvågor. Dessa kan upptäckas med t.ex. konvolutionella neurala nätverk. [6]

Då man söker efter detektorstörningar använder man sig, förutom av gravitationsvågsdetektorerna, även av ljudkanaler (eng. auxiliary channel). Dessa ljudkanaler uppmäter inte gravitationsvågor. Man kan då avfärda pikar som även återfinns i ljudkanalernas grafer som störningar. Maskininlärningsalgoritmerna tränas att hitta störningar med ljudkanalernas data som träningsdata. [6]

Man har, precis som för slumpskogar, undersökt hur väl konvolutionella neurala nätverk lämpar för att upptäcka gravitationsvågor från kompakta binära sammansmältningar, samt bestämma parametrarna för dem. Det man kommit fram till är att konvolutionella neurala nätverk är ungefär lika bra på att upptäcka gravitationsstrålning från binära svarta hål som matchad filtrering. Dessutom har man visat att vertyget Bambi, som använder sig av nästlad sampling och neurala

nätverk, kan bestämma källors parametrer mycket snabbare än renodlad nästlad sampling som används för Bayesisk inferens. [6]

Man har också lyckats bestämma positionen för binära svarta hål med hjälp av neurala nätverk. Man matade nätverket i fråga med tidsfördröjningar, amplitudförhållanden och fasskillnader mellan olika detektorer. Man lyckades bestämma positionen med högre än 90% sannolikhet då man delade upp himlen i 18-128 sektorer. Man arbetar med att utvidga metoden för att bestämma positionen för binära neutronstjärnor och system bestående av en neutronsstjärna och ett svart hål. [6]

3.4 Jämförelse mellan slumpskogar och neurala nätverk

Ett problem med neurala nätverk är att de överanpassar (eng. overfit). Det innebär att de fäster för stor uppmärksamhet vid enskilda träningsdataobjekt, och "med våld" ser till att även de passar in i modellen. Detta resulterar i bristfällig klassificeringsförmåga av nya objekt. Överanpassning kan vara ett resultat av att man valt fel arkitektur för det neurala nätverket, vilket är vanligt om det inte finns befintlig kunskap om hur man tar sig an ett specifikt område med hjälp av neurala nätverk. På grund av detta utklassar slumpskogar neurala nätverk inom domäner där slumpmässighet är betydande. Överanpassningen inom neurala nätverk är också en konsekvens av att de använder sig av många parametrar, och därmed kan finjusteras till den grad att resultaten lider.

Slumpskogar är en generell metod, och enligt [19] finns det ofta ett färdigt paket man kan utnyttja som utklassar andra metoder enligt.

Neurala nätverk lämpar sig väl för bildklassificering. [19]

4 Avslutning

På basen av uppgifter i presenterade källor kan man konstatera att slumpskogar verkar vara ett effektivare verktyg för att upptäcka gravitationsvågor än matchad filtrering och neurala nätverk. Både slumpskogar och neurala nätverk är snabbare än Bayesisk inferens för att bestämma parametrar för gravitationsvågskällor. Slutligen fastställdes att neurala nätverk lämpar sig väl för att bestämma positionen för gravitationsvågskällor.

5 Referenser

- [1] Thorne, Kip S., 1995, Gravitational Waves, s. 1, 3, <https://arxiv.org/pdf/gr-qc/9506086.pdf>
- [2] Abbot, B.P. et al., 2016, Observation of Gravitational Waves from a Binary Black Hole Merger, s. 1-2, <https://arxiv.org/ftp/arxiv/papers/1602/1602.03837.pdf>
- [3] LIGOs hemsida, <https://www.ligo.caltech.edu/page/why-detect-gw>
- [4] The LIGO Scientific Collaboration and the VIRGO Collaboration, et al., 2017, A gravitational-wave standard siren measurement of the Hubble constant, s. 1, <https://arxiv.org/pdf/1710.05835.pdf>
- [5] Timothy D. Gebhard, et al., 2019, Convolutional neural networks: A magic bullet for gravitational-wave detection?, s. 1, 2-3, <https://journals.aps.org/prd/pdf/10.1103/PhysRevD.100.063015>
- [6] Cuoco, Elena, 2020, Enhancing gravitational-wave science with machine learning, s. 1, 5-8, 13-14, 19-20, 22, <https://arxiv.org/pdf/2005.03745.pdf>
- [7] T. Accadia, et al., 2012, Virgo: a laser interferometer to detect gravitational waves, s. 3, <https://iopscience.iop.org/article/10.1088/1748-0221/7/03/P03012/pdf>
- [8] Abbott, et al., LIGO: The Laser Interferometer Gravitational-Wave Observatory, s. 7-8 <https://arxiv.org/pdf/0711.3041.pdf>
- [9] Caprini, Chiara, 2019, Detecting gravitational waves from cosmological phase transitions with LISA: an update, s. 4, <https://arxiv.org/pdf/1910.13125.pdf>
- [10] Kibble, T.W.B., 2004, Cosmic Strings Reborn?, <https://arxiv.org/pdf/astro-ph/0410073.pdf>
- [11] Ali, Jehad, 2012, Random Forests and Decision Trees, s. 2, <https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.402.3863&rep=rep1&type=pdf>
- [12] Analytics Vidhya, 2020, Decision Tree Full Course | #4. How to Select the Best Split Point in Decision Trees, <https://www.youtube.com/watch?v=6xjYzIdwPIY>
- [13] Briauc, Marine, A Practical Introduction to Random Forest for Genetic Association Studies in Ecology and Evolution, s. 5, <https://onlinelibrary.wiley.com/doi/am-pdf/10.1111/1755-0998.12773>
- [14] Biau, Gerard, A Random Forest Guided Tour, s. 1, <https://arxiv.org/pdf/1511.05741.pdf>
- [15] Kröse, Ben, 1996, An introduction to Neural Networks, s. 16, 18, 24-25, <http://citeseerx.ist.psu.edu/viewdoc/download?jsessionid=31693EFE24B63C9039CFC4D8A9958070?doi=10.1.1.18.493&rep=rep1&type=pdf>

- [16] Ma, Tengyu, et al., Deep Learning, s. 2, 6,
http://cs229.stanford.edu/notes2020fall/notes2020fall/deep_learning_notes.pdf
- [17] Krastev, Plamen G., 2020, Real-time detection of gravitational waves from binary neutron stars using artificial neural networks,
<https://www.sciencedirect.com/science/article/pii/S0370269320301349>
- [18] Phuloria, Vivek, 2020, Neural Networks Explained — Deep Learning 101,
<https://towardsdatascience.com/deep-learning-101-neural-networks-explained-9fee25e8ccd3>
- [19] Wang, Suhang, Random-Forest-Inspired Neural Networks, s. 2,
<https://dl.acm.org/doi/pdf/10.1145/3232230>