


Warming^{UP}GOO

Geothermie & Opslag Opschaling



AI interpretatie van geologische formaties en breuken

Toepassing van AI tools op Warming^{UP}GOO ondergrondse structuren

door

Dr. Stefan Carpentier

17 januari 2025

AI interpretatie van geologische formaties en breuken



Stefan Carpentier
17 januari 2025

Kwaliteitsborgers
Mark Vrijlandt (TNO)
Henk van Lochem (EBN)

De werkzaamheden voor dit rapport zijn uitgevoerd als onderdeel van het project WarmingUP Geothermie en Opslag Opschaling (Warming^{UP}GOO). Dit is mede mogelijk gemaakt door subsidie van de Rijksdienst voor Ondernemend Nederland (RVO) in het kader van de subsidieregeling Missiegedreven Onderzoek, Ontwikkeling en Innovatie (MOOI), bij RVO bekend onder projectnummer MOOI322012. Warming^{UP}GOO geeft invulling aan MOOI-missie B *Gebouwde Omgeving* en levert een bijdrage aan innovatiethema *Duurzame collectieve warmtevoorziening*.

Projectnummer
60376

Keywords
AI, ML, geofysische interpretatie, seismische data

Jaar van publicatie
2025

Meer informatie
Lies Peters
E Lies.peters@tno.nl

jan/2025 ©

Alle rechten voorbehouden. Niets uit deze uitgave mag worden verveelvoudigd, opgeslagen in een geautomatiseerd gegevens bestand, of openbaar gemaakt, in enige vorm of op enige wijze, hetzij elektronisch, mechanisch, door fotokopieën, opnamen, of enig andere manier, zonder voorafgaande schriftelijke toestemming van de uitgever.

Inhoudsopgave

Samenvatting	4
Summary	4
1 Inleiding	5
2 Methodes en resultaten	8
2.1.1 AI seismische data conditionering	8
2.1.2 AI seismische data interpretatie	11
2.1.3 AI seismische breuk detectie	15
3 Discussie en conclusies	19
4 Referenties	20

Samenvatting

In het kader van het Warming^{UP}GOO project zijn Machine Learning (ML) methodes getest en is een toolkit ontwikkeld voor interpretatie van (onshore) seismische data van het ondiepe en midden-diepe bereik (~300 - 1500 m). Het doel is om dit diepte bereik snel te kunnen karakteriseren door efficiënte interpretatie van horizons en breuken in seismische data. De eerste stap is signaalverbetering door middel van ruisonderdrukking en interpolatie met AI-technieken. De volgende stap is om horizons en breuken met een minimale set trainingsdata te interpreteren door gebruik te maken van (semi-) self-supervised methodes. De opgeleverde toolkit ondersteunt de toepassing van de geïmplementeerde algoritmes voor een efficiënte workflow. Een eerste demonstratie is gegeven voor de interpretatie van de top van de Maassluis Formatie in de Leeuwarden 3D seismische data.

Summary

In the framework of the Warming^{UP}GOO project, Machine Learning (ML) methods have been tested and implemented in a toolkit for the interpretation of (onshore) seismic data from the shallow to mid-depth range ~300 - 1500 m). The goal is to characterise this depth domain fast by efficient interpretation of horizons and faults in seismic data. The first step is to improve the signal by applying AI techniques for noise reduction and interpolation. Next, horizons and faults are interpreted with minimal use of human-generated training data by using (semi-) self-supervised methods. The toolkit that has been delivered supports the application of the implemented algorithms in an efficient workflow. As a first demonstration, the top of the Maassluis Formation has been interpreted in the Leeuwarden 3D seismic cube.

1 Inleiding

Het MOOI project Warming^{UP}GOO (WarmingUP Geothermie en Opslag Opschaling) richt zich op de opschaling en versnelling van geothermie en HTO. Geothermie en HTO zijn sterk met elkaar verbonden, en kennen vergelijkbare belemmeringen:

1. Gegevens van de ondergrond zijn juist voor de bodemlagen waar HTO en ondiepe geothermie zich op richten, slechts beperkt beschikbaar.
2. Veel van de ondergrond gegevens zijn verzameld en geprocesst met een focus op diepere lagen.
3. HTO-systemen zijn in Nederland nog in de pilotfase: voor opschaling is ervaring opdoen, kennisontwikkeling en kennisdeling nodig.
4. Bij geothermie is meer ervaring, daar kan een betere benutting van beschikbare data bijdragen verhoging van de efficiency van individuele installaties en van sector als geheel.
5. Het verkrijgen van maatschappelijk draagvlak is voor zowel geothermie als HTO een punt van aandacht.

Dit rapport beschrijft werkzaamheden in het kader van het verbeteren van de karakterisatie van de ondergrond voor HTO en ondiepe geothermie (< 1500 m). Specifiek gaat het hier om innovatieve (merendeels AI gebaseerde) geautomatiseerde workflows voor hogere resolutie interpretaties van bestaande 3D en 2D seismiek resulterend in verbeterde karakterisatie van lagen en breukdichtheid.

Conventionele seismische interpretatie en breukdetectie maakt gebruik van handmatige picking, getrackte picking en seismische attributen voor horizons en breuken met behulp van routines zoals OpendTect auto-tracking en Petrel ant-tracking. Dit is omslachtig en leidt tot onderbenutting van gegevens, aangezien in 3D-onderzoeken slechts een beperkt deel van alle gegevens wordt geïnterpreteerd/gepickt. Wij stellen voor om de interpretatie van seismische gegevens in de Nederlandse ondergrond op te schalen door horizons en breuken te interpreteren en te picken in het volledige scala aan gegevens in Nederlandse 3D-onderzoeken in plaats van slechts een subset van inlines en crosslines door het gebruik van Machine Learning (ML)-algoritmen.

Next-generation Machine Learning-tools die neurale netwerken trainen en toepassen voor geautomatiseerde horizon- en breukdetectie zijn ontwikkeld door marktpartijen en zijn verbeterd inhouse door TNO. Hoewel over het algemeen succesvol en ordes van grootte sneller, blijven er nog veel onnauwkeurigheden in deze ML-voorspellingen ten opzichte van menselijke interpretatie/picking.

Ten behoeve van deze opschaling zullen we de in de ML-tools gebruikte state-of-the-art ML-algoritmen inspecteren, conditioneren, trainen, hertrainen, corrigeren met de expertise en kennis van menselijke interpreters en de beschikbare hoeveelheid aan horizons en breuken, bijvoorbeeld de DGM Diep/Ondiep datasets. We ontwikkelen daarbij een workflow voor eenvoudige, gebruiksvriendelijke, laagdrempelige interactie met de ML-tools. De toepassing van de ML-tools zal zich richten op onshore ondiepe tot middel-diepe reservoirs/aquifers voor HTO en geothermische exploratie. Ze werken voornamelijk op conventionele 2D- en 3D-seismische gegevens, geconditioneerd door boorlogs, en zullen op basis van die gegevens *seismische horizons* en geologische eenheden voorspellen. Een voorbeeld van het ontwerp van zo'n AI-softwaretool is te zien in Figuur 1 en in Figuur 2 is een eerste-orde voorspelling van geologische eenheden te zien.

Verder omvat deze activiteit en dit rapport de ontwikkeling en eerste test van een next-generation ML toolkit gericht op het verbeteren van *breuken-interpretatie* op verschillende vintage seismische datasets in de bovenste 500 m diepte, wat een terugkerend probleem is voor de Nederlandse ondergrond. Uiteindelijk zal Warming^{UP}GOO eindigen met een kant-en-klare AI-softwaretool die seismische gegevens en logs als invoer gebruikt, en die output genereert over voorspelde seismische horizons en geologische eenheden en breuken.




Fig 1. Algemene architectuur van AI neural networks (Ronneberger et al., 2015; Chai et al, 2020). Een AI neural network leert de relatie of 'mapping' tussen de aangeboden Input en de aangeboden True Target. Het netwerk wordt getraind door iteraties te doorlopen waarbij het verschil tussen de Output en True Target wordt geminimaliseerd. Als het verschil minimaal wordt, is het netwerk getraind en kan het aan de hand van aangeboden Input betrouwbare Output voorspellen, bijvoorbeeld classificatie van lithologie, facies, horizons, breuken etc. Het linker plaatje laat de schematische architectuur van het neural network zien en het rechterplaatje laat de datastroom door het neural network zien.




Fig 2. U-net training en validerende voorspelling van geologische eenheden in Nederlandse 3D onshore data. Een U-net is een convolutioneel neurale netwerk ontwikkeld voor beeld segmentatie (Ronneberger et al., 2015). Twee voorbeelden van een seismische sectie, boven en onder, niet gebruikt in de training van het U-net netwerk. X = Input, Y = menselijke interpretatie, Prediction = AI validerende voorspelling. Y en Prediction zouden zo gelijk mogelijk moeten zijn bij een succesvol getraind netwerk.

2 Methodes en resultaten

2.1.1 AI seismische data conditionering

De onderzoeksvraag en -strategie voor AI data conditioning is:

Uitdaging: Automatisch conditioneren van seismische data op grote hoeveelheden vintage 2D- en 3D-seismische data voor geothermische exploratie.

Methode: Denoising met Self-supervised learning (“Noise2Void”, Birnie et al., 2021) en data outliers en gaps interpoleren met een Generative Adversarial Network (“MDA-GAN”, Dou et al., 2022, (a)) voor het uiteindelijke doel van classificeren van over- en underburden van gegeven horizons, getraind op opgeschoonde 3D Inlines en Crosslines.

Resultaten: Succesvolle conditioned data met beter gedefinieerde Maassluis- en Oosterhout-reflecties in een pilot 3D-seismische cube.

Ruisonderdrukking is een essentiële stap in veel seismische processing workflows. Een deel van deze ruis, met name in land datasets, manifesteert zich als willekeurige ruis. In de afgelopen jaren zijn neurale netwerken met succes gebruikt om seismische gegevens op een gecontroleerde manier te denoisen. Gecontroleerd AI learning komt echter altijd met de vaak onbereikbare eis om ruisvrije datasets te hebben voor training. Met AI blind-spot netwerken herdefiniëren we de denoising-taak als een self-supervised procedure waarbij het netwerk de omringende seismische ruis gebruikt om de ruisvrije waarde van een centraal sample te schatten. Op basis van de aanname dat ruis statistisch onafhankelijk is tussen monsters, kan het netwerk de ruiscomponent van het sample voorspellen vanwege de willekeurigheid, terwijl de signaalcomponent nauwkeurig wordt voorspeld vanwege de spatio-temporele coherentie. Geïllustreerd op synthetische voorbeelden, blijkt het blind-spot netwerk een efficiënte denoiser te zijn van seismische gegevens die zijn verontreinigd door willekeurige ruis met minimale schade aan het signaal waardoor verbeteringen worden geboden in zowel het beelddomein als in latere taken, zoals post-stack inversie. In dit onderzoek gebruiken we de methoden van Birnie et al. (2021), geïllustreerd in Figuur 3 en Dou et al. (2022), geïllustreerd in Figuur 4.

De figuren 5, 6 en 7 laten zien hoe met de AI self-supervised denoised methode van Birnie et al. (2021) in de voorbeeld 3D survey “Leeuwarden” (Figuur 5) de ruis succesvol onderdrukt wordt zonder signaal te schaden (Figuur 6) en hoe met de AI Generative Adversarial Network (GAN) interpolatie methode van Dou et al. (2022, (a)) de continuïteit van ondiepe reflectoren verbeterd wordt (Figuur 7).




Fig. 1. Schematic illustration of the Noise2Void denoising procedure.

Fig 3. Schema van AI tool neural network Self-Supervised Denoising “Noise2Void” (Birnie et al., 2021). Een Self-Supervised Denoising neural network leert de relatie of ‘mapping’ tussen de aangeboden corrupte noisy Patch met en de aangeboden oorspronkelijke noisy Patch. Het netwerk wordt getraind door iteraties te doorlopen waarbij het netwerk de onvoorspelbare corrupted pixel in de corrupted noisy Patch niet kan reproduceren maar het voorspelbare achtergrond signaal wel en daarmee effectief de input noisy Patch denoised.




Fig 4. Concept van AI tool neural network Generative Adversarial Network (GAN) interpolatie “MDA-GAN” (Dou et al., 2022, (a)). Een conditional Generative Adversarial Network (GAN) leert de relatie of ‘mapping’ tussen de aangeboden input seismiek met gaten erin (Input) en de aangeboden oorspronkelijke seismiek zonder gaten (GT). Het netwerk wordt getraind door iteraties te doorlopen waarbij het netwerk de gaten in de seismiek vult met steeds realistischer 3D complexe geologische patronen die aansluiten op de 3D contextuele structuur van de omliggende onverstoorde seismische traces.




Fig 5. Nederlandse onshore 3D seismic cube “Leeuwarden”, originele noordelijkste full inline en timeslice 1200 ms.




Fig 6. Nederlandse onshore 3D seismic cube “Leeuwarden”, AI self-supervised denoised noordelijkste full inline en timeslice 1200 ms. Het resultaat is minimale signal leakage en maximale amplitude en phase preservation.




Fig 7. Nederlandse onshore 3D seismic cube “Leeuwarden”, AI GAN interpolated noordelijkste full inline en timeslice 1200 ms. Het resultaat is maximale gap filling plus amplitude en phase preservation.

2.1.2 AI seismische data interpretatie

De onderzoeksvraag en -strategie voor AI horizon interpretatie is:

Uitdaging: Automatisch interpreteren van geologische horizons op grote hoeveelheden vintage 2D- en 3D-seismische data voor geothermische exploratie.

Methode: Beeldsegmentatie met behulp van semi-supervised learning (CONSS, Li et al., 2023) voor het classificeren van over- en onderburden van gegeven horizons, trainen op opgeschoonde 3D Inlines en Crosslines.

Resultaten: Succesvol voorspelde Maassluis- en Oosterhout-horizons in alle Inlines en Crosslines van een pilot 3D-seismische cube.

De volgende stap is het AI interpreteren van de opgeschoonde seismische data. Recentelijk heeft seismische interpretatie op basis van convolutionele neurale netwerken (CNN) aanzienlijke vooruitgang geboekt. Bestaande CNN-gebaseerde AI supervised learning methoden vereisen echter enorme hoeveelheden gelabelde gegevens. Het labelen is arbeidsintensief en tijdrovend, vooral voor 3D-seismische datavolumes. Om deze problemen op te lossen, stellen Li et al. (2023) een semi-supervised methode op basis van contrastive learning, genaamd CONSS, die efficiënt geologische eenheden kan identificeren met slechts 1% van de oorspronkelijke menselijke interpretaties. Figuur 8 laat het schema van deze AI tool zien. Experimentele resultaten tonen aan in het onderzoek van Li et al. (2023) dat deze aanpak state-of-the-art prestaties behaalt op de Nederlandse openbare F3 seismische survey.




Fig. 2. The CONSS pipeline consists of a backbone network that extracts features, a segmentation head for fully supervised learning, and a representation head for contrastive learning. The representation head imposes additional constraints on network learning by optimizing the feature space distribution through contrastive learning.

Fig 8. Schema van AI tool neural network CONSS (Li et al., 2023). Een semi-supervised Contrastive Learning AI neural network leert de relatie of ‘mapping’ tussen de aangeboden Input en de aangeboden True Target. Het netwerk wordt eerst getraind naar een pretrained model met veel algemene seismische data, om voorspellingen te laten doen op nieuwe seismische data en het pretrained model te her-trainen naar een nieuw model met Contrastive Learning. Hiermee wordt een algemeen AI neural network specifiek getraind op een nieuwe dataset met weinig benodigde trainings-data.

Figuren 9, 10, 11, 12 en 13 tonen de resultaten van de gecombineerde workflow: 1) seismic data AI denosing, 2) seismic data AI interpolation, 3) AI interpretatie en 4) menselijke correctie van AI interpretatie. Figuur 10 toont de AI interpretatie van de “Leeuwarden” conditioned 3D cube (Figuur 9) met als trainingsdata de DGM Diep en DGM Ondiep geïnterpreteerde Maassluis, Oosterhout, Breda en Lower Northsea horizons gedefinieerd op slechts 11 inlines. Het is te zien dat de interpretatie in 3D zeer consistent en plausibel is, maar dat de training interpretatie van met name de Maassluis en Oosterhout Formaties op veel plekken niet klopt met lokale seismische reflecties. Dit komt omdat het DGM Ondiep model enkel op boorgegevens is gebaseerd en niet op shallow seismiek. Daarom is een interactieve “Human-in-the-loop (HITL)” module door TNO ontwikkeld, die menselijke correctie van AI interpretaties mogelijk maakt. Een screenshot van deze tool is te zien in Figuur 11, waarbij een line-drawing tool met snap-to-peak interactief op de oude AI interpretatie gedaan kan worden en de correctie opnieuw wordt getraind met het AI netwerk. Het resultaat daarvan is te zien in Figuur 12, waar de Top Maassluis (paars) de corresponderende seismische reflector volgt. In Figuur 13 is door deze verbeterde AI interpretatie zelfs een Elsterian Glacial Valley automatisch geïdentificeerd door de AI tool. Hiermee is de AI interpretatie workflow zeer overtuigend ontworpen en gedemonstreerd binnen Resultaat 1, Taak 1.4, Activiteit 1.4.3.




Fig 9. Nederlandse onshore 3D seismic cube "Leeuwarden". Conditioned inline en crossline.




Fig 10. Nederlandse onshore 3D seismic cube "Leeuwarden". CNN semi-supervised classified facies op inline en timeslice. Slechts 1% labelled facies nodig voor training, 11 inlines in hele cube. Kleurcodes top-to-bottom: lila: Maassluis, lichtblauw: Oosterhout, lichtgroen: Breda, geel: Boven Noordzee, donkerpaars: Onder Noordzee. Figuur oriëntatie en schalen: boven = noord, onder = zuid, links = west, rechts = oost; Oost-west afstand = 28 km, noord-zuid afstand = 15 km, dieptebereik = 1200 ms (+/- 1 km).




Fig. 11. Nederlandse onshore 3D seismic cube “Leeuwarden”. CNN semi-supervised classified facies op inline. Slechts 1% labelled facies nodig voor training, 11 inlines in hele cube. Prototype interpretatie / labelling tool op inline. Kleurcodes van boven naar beneden: rood: Tertiair, lichtrood: Maassluis, lichtroze: Oosterhout, wit: Breda, lichtblauw: Boven Noordzee, donkerblauw: Onder Noordzee. Figuur oriëntatie en schalen: links = west, rechts = oost; Oost-west afstand = 8 km, dieptebereik = 1000 ms (+/- 0.8 km). Dikke rode lijn is handmatige, snap-to-peak interpretatie voor her-training neurale netwerk.




Fig 12. Nederlandse onshore 3D seismic cube “Leeuwarden”. CNN semi-supervised classified facies op inline en timeslice, Slechts 1% labelled facies nodig voor training, 11 inlines in hele cube. Reinterpreted en re-predicted Top Maassluis. Kleurcodes top-to-bottom: lila: Maassluis, lichtblauw: Oosterhout, lichtgroen: Breda, geel: Boven Noordzee, donkerpaars: Onder Noordzee. Figuur oriëntatie en schalen: boven = noord, onder = zuid, links = west, rechts = oost; Oost-west afstand = 28 km, noord-zuid afstand = 15 km, dieptebereik = 1200 ms (+/- 1 km).




Fig 13. Nederlandse onshore 3D seismic cube “Leeuwarden”. CNN semi-supervised classified facies op ondiepere timeslice. Slechts 1% labelled facies nodig voor training, 11 inlines in hele cube. Glaciale Elsterian valley herkend, reinterpreted Top Maassluis. Kleurcodes top-to-bottom: lila: Maassluis, lichtblauw: Oosterhout, lichtgroen: Breda. De meanderende infill van de (lila) Maassluis in de lichtblauwe Oosterhout representeert de Elsterian Valley.

2.1.3 AI seismische breuk detectie

De onderzoeks-vraag en -strategie voor AI breuk detectie in Resultaat 1, Taak 1.4, Activiteit 1.4.3 is:

Uitdaging: Automatisch interpreteren van breuken op grote hoeveelheden vintage 2D- en 3D-seismische data voor geothermische exploratie.

Methode: Beeldsegmentatie met semi-supervised learning netwerk “FaultSSL” (Dou et al., 2022 (b), Dou et al., 2023) voor breuken-detectie in seismische data, trainen op originele seismische cube.

Resultaten: Succesvol voorspelde breuken in Maassluis- en Oosterhout Formaties in alle Inlines en Crosslines van een pilot 3D-seismische cube.

Breukdetectie is een cruciale stap in energie exploratie. Traditionele methoden vertrouwen op seismische attributen en andere processing- en imaging-technieken, die gevoelig zijn voor processing-parameters en ruis. Dit werk richt zich op AI methoden.

De moeilijkheid om nauwkeurige labels te verkrijgen is altijd een serieus probleem geweest bij data-gedreven breukdetectie. De complexiteit van de 3D-verdeling van breuken maakt het bijna onmogelijk om handmatig volledige seismische breuk-labels te verkrijgen. De 2D-labels zijn relatief eenvoudig te verkrijgen, maar 2D-breukdetectie heeft inherente gebreken, zoals de discontinuïteit van 2D-interpretaties in driedimensionale ruimte, het onvermogen om voldoende ruimtelijke en context informatie te verkrijgen, etc.




Fig 14. Schema van AI tool neural network FaultNet (Dou et al., 2022 (b)). Netwerk is U-net autoencoder met speciale weighted labels, om breuken parallel aan Inlines en Crosslines goed te behandelen.




Fig. 1. FaultSSL's PNC and PTC proxy task flowchart.

Fig 15. Schema van AI tool neural network FaultSSL (Dou et al., 2023). Een semi-supervised AI neural network leert de relatie of 'mapping' tussen de aangeboden Input en de aangeboden True Target. Het netwerk wordt getraind door een pretrained Teacher model, getraind met algemene seismische data, voorspellingen te laten doen op nieuwe seismische data en het Teacher model te her-trainen naar een Student model met de meest betrouwbare voorspellingen van het Teacher model als trainings-data. Hiermee wordt een algemeen AI neural network specifiek getraind op een nieuwe dataset met weinig benodigde trainings-data.




Fig 16. Nederlandse onshore 3D seismic cube “Waalwijk”, CNN semi-supervised Fault detectie, FaultSSL, 3D resultaat, slechts kleine hoeveelheid % labelled faults nodig, pretrained model, retraining met distilled learning mogelijk. Gele lijnen zijn door FaultSSL voorspelde breuken (probability +- 1) geprojecteerd op input data Waalwijk.




Fig 17. Nederlandse onshore 3D seismic cube “Waalwijk”, originele inline.

Om de generalisatie van modellen die zijn getraind op beperkte synthetische datasets naar een breder scala aan veld-seismische data te verbeteren, introduceren Dou et al. (2023) FaultSSL, een semi-supervised AI breukdetectie. Deze methode is gebaseerd op de klassieke teacher-student structuur, waarbij het supervised deel synthetische gegevens en enkele 2D-labels gebruikt. Het unsupervised deel vertrouwt op twee zorgvuldig ontworpen proxy-taken, waardoor het enorme hoeveelheden niet-gelabelde veld-seismiek in het trainingsproces kan opnemen. Figuren 14 en 15 laten de architectuur van het AI netwerk van Dou et al. (2022 (b)) en Dou et al. (2023) zien.

Figuren 16 en 17 tonen de resultaten van de workflow: 1) AI interpretatie van breuken. In deze figuren is de AI breuk-detectie van de “Waalwijk” 3D cube uitgevoerd door een pre-trained model. Dit pre-trained model is door Dou et al. (2023) getraind op synthetische breuken en ge-finetuned

op veld-seismische data en breuken van de F3-cube in de Nederlandse offshore, gedefinieerd op slechts 1% van de F3 inlines. Het is te zien dat de breuk interpretatie in 3D (Figuur 16) zeer consistent en plausibel is, en dat de breuken zelf tot in de Maassluis en Oosterhout Formaties gedetecteerd worden (Figuur 17, ondiep tot +- 200 ms), kloppend met de seismische reflecties. Hiermee is de AI breuk-detectie workflow zeer overtuigend ontworpen en zelfs gedemonstreerd binnen Resultaat 1, Taak 1.4, Activiteit 1.4.3.

3 Discussie en conclusies

De workflow van AI netwerken ontworpen in Resultaat 1, Taak 1.4, Activiteit 1.4.3 is nu volwassen en presteert goed op synthetische en veld-seismische data. Training op synthetische gegevens werkt altijd goed, training op veldgegevens is wisselend, de labels zijn niet altijd consistent of juist (soms gebaseerd op enkel boorgegevens) en schaalvariant.

De 3D consistentie van de AI voorspelde geologische eenheden, horizons en breuken is zeer overtuigend en bruikbaar, zelfs in het ondiepe domein van de Maassluis en Oosterhout Formaties. De volgende stap is om deze workflow toe te passen op de target gebieden van Warming^{UP}GOO.

4 Referenties

Birnie, C., Ravasi, M., Liu, S., Alkhalifah, T., (2021), The potential of self-supervised networks for random noise suppression in seismic data, *Artificial Intelligence in Geosciences* 2, p 47-59.

Chai, X., Gu, H., Li, F., Duan, H., Hu, X., Lin, K., (2020), Deep learning for irregularly and regularly missing data reconstruction, *Nature Sci Rep* 10, 3302. <https://doi.org/10.1038/s41598-020-59801-x>

Dou, Y., Li, K., Duan, H., Li, T., Dong, L., Huang, Z., (2022, (a)), MDA GAN: Adversarial-Learning-based 3-D Seismic Data Interpolation and Reconstruction for Complex Missing, *arXiv:2204.03197*.

Dou, Y., Li, K., Zhu, J., Li, T., Tan, S., Huang, Z., (2022, (b)), MD loss: Efficient training of 3-D seismic fault segmentation network under sparse labels by weakening anomaly annotation, *IEEE Transactions on Geoscience and Remote Sensing*, Volume 60, pages 1—14.

Dou, Y., Li, K., Dong, M., Xiao, Y., (2023), FaultSSL: Seismic Fault Detection via Semi-supervised learning, *Geophysics*, volume 89, Number 3, Pages 1—43.

Li, K., Liu, W., Dou, Y., Xu, Z., Duan, H., Jing, R., (2023), CONSS: Contrastive Learning Approach for Semi-Supervised Seismic Facies Classification, *ArXiv 2210.04776v3*.

Ronneberger, O., Fischer, P., Brox, T., (2015), U-Net: Convolutional Networks for Biomedical Image Segmentation, *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*.

Warming^{UP}GOO

Geothermie & Opslag Opschaling

Adres

Princetonlaan 6
3584 CB Utrecht

Postadres

Postbus 80015
3508 TA Utrecht

Telefoon

088 866 42 56

E-mail

contact@warmingup.info

Website

www.warmingup.info