



RUB



EUROPÄISCHE UNION
Investition in unsere Zukunft
Europäischer Fonds
für regionale Entwicklung




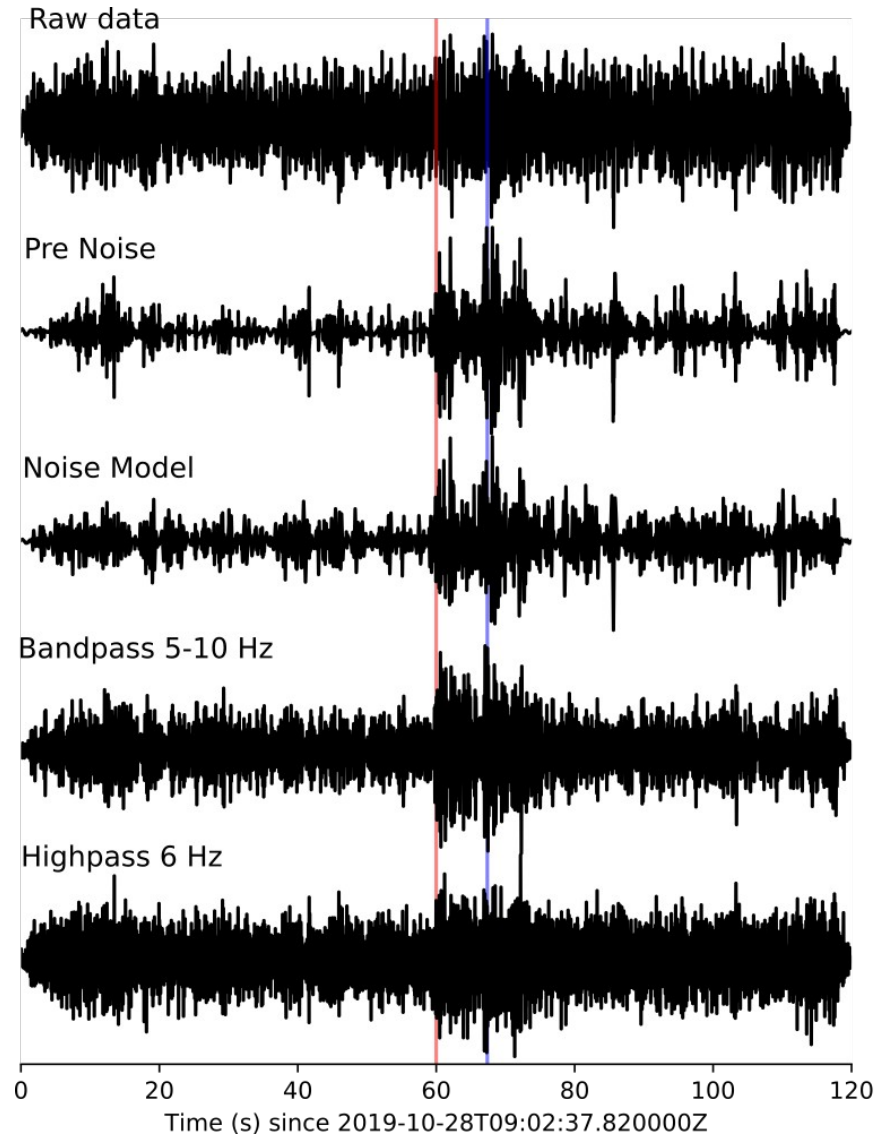
EFRE.NRW
Investitionen in Wachstum
und Beschäftigung

RUHR-UNIVERSITÄT BOCHUM


Denosing Autoencoder

Janis Heuel, Wolfgang Friederich

Letztes Meeting am 27.10.2020




Filtermethoden




- Test mit DeepDenoiser von Zhu et al. (2019) funktionierte bei Tobi schon gut
- Erste Anwendung im Dez. 2020 zeigte solide Ergebnisse
→ bessere Ergebnisse als CWT Thresholding
- Vielleicht funktioniert der DeepDenoiser mit der CWT besser als mit der STFT?


Denoising Autoencoder



Funktionsweise eines DAE



0. Zeit-Frequenz Darstellung des Zeitfenster und Unterteilung in real und imaginär Teil




Funktionsweise eines DAE

1. 2D Convolution



https://d2l.ai/chapter_convolutional-neural-networks/padding-and-strides.html



→ Dimensionsreduktion des Eingabebildes

→ Kernel / Filter wird trainiert und dient als Neuron


2. Batch Normlization

Normierung der tieferen Schichten (hidden layers) mit Hilfe des Mittelwerts und Standardabweichung → schnelleres Training eines neuronalen Netzwerks

3. Aktivierungsfunktion (ReLU)

Wenn Eingabewert nicht stimmt (hier ≤ 0), dann löst das Neuron nicht aus


Funktionsweise eines DAE



4. Wiederholen von Schritt 1-3


→ starke Dimensionsreduktion, aber Erzeugung zahlreicher Kernel / Filter

5. Transpose 2D Convolution + Schritte 1 – 3, aber Conv2D ohne Dimensionsreduktion (zero padding)



<https://medium.com/apache-mxnet/transposed-convolutions-explained-with-ms-excel-52d13030c7e8>


Funktionsweise eines DAE



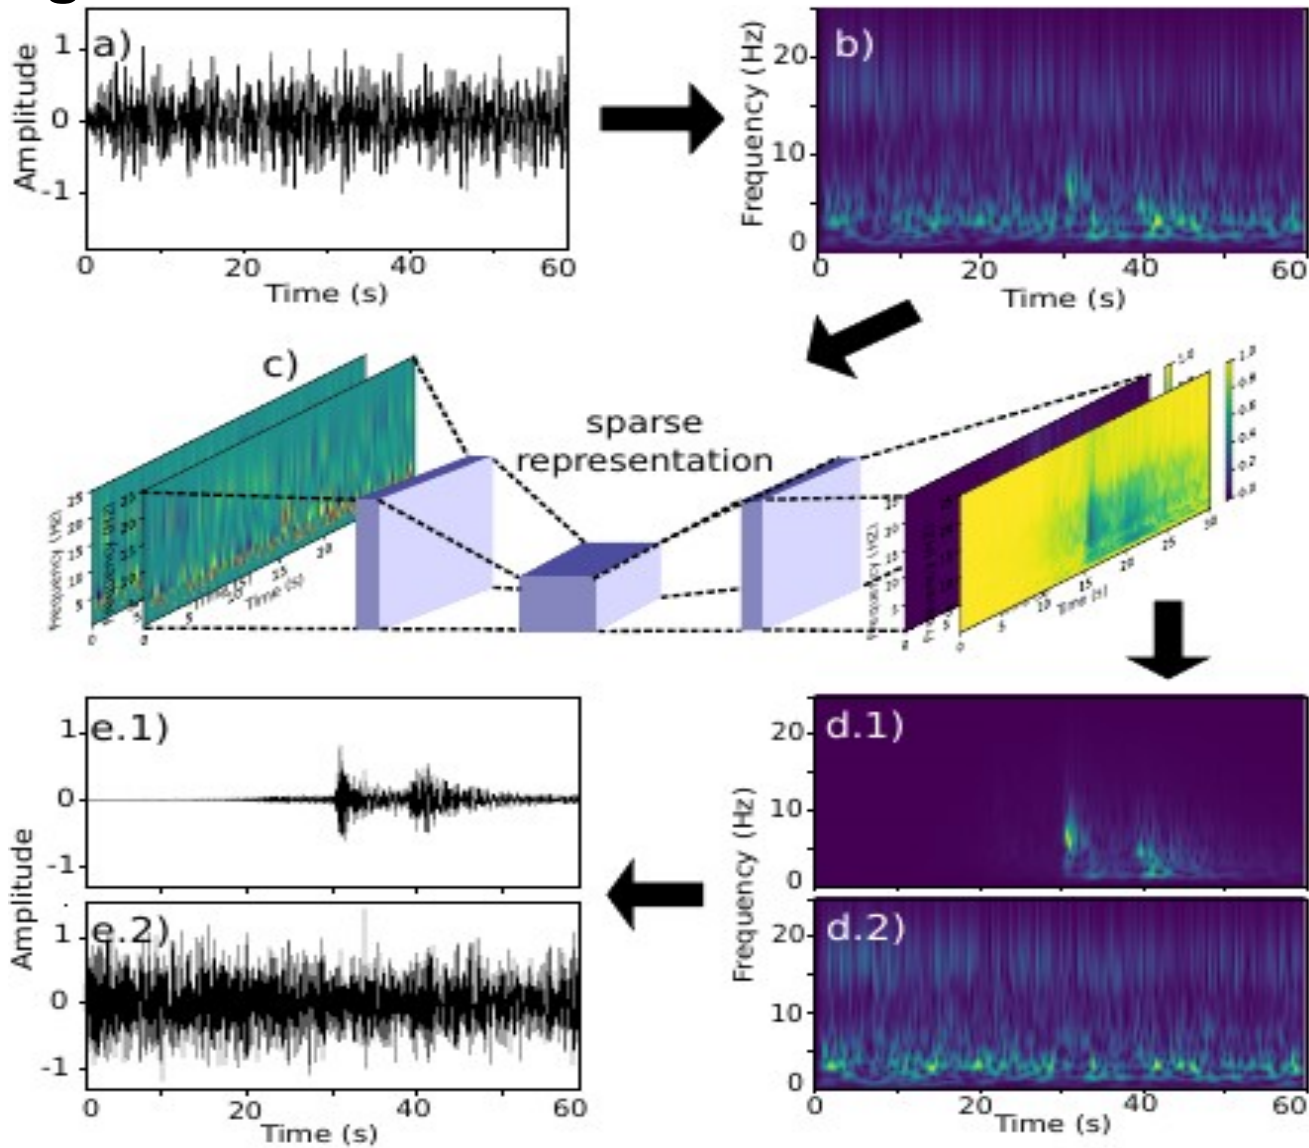
6. 2D Convolution, so dass Eingangsdimension wieder erreicht wird

7. Softmax Layer

→ So haben Output Layer nur Zahlen im Bereich $[0, 1]$




Denoising Autoencoder



Training eines DAE

Stanford EArthquake Dataset (STEAD): A Global Data Set of Seismic Signals for AI, Mousavi et al, 2019



Training eines DAE

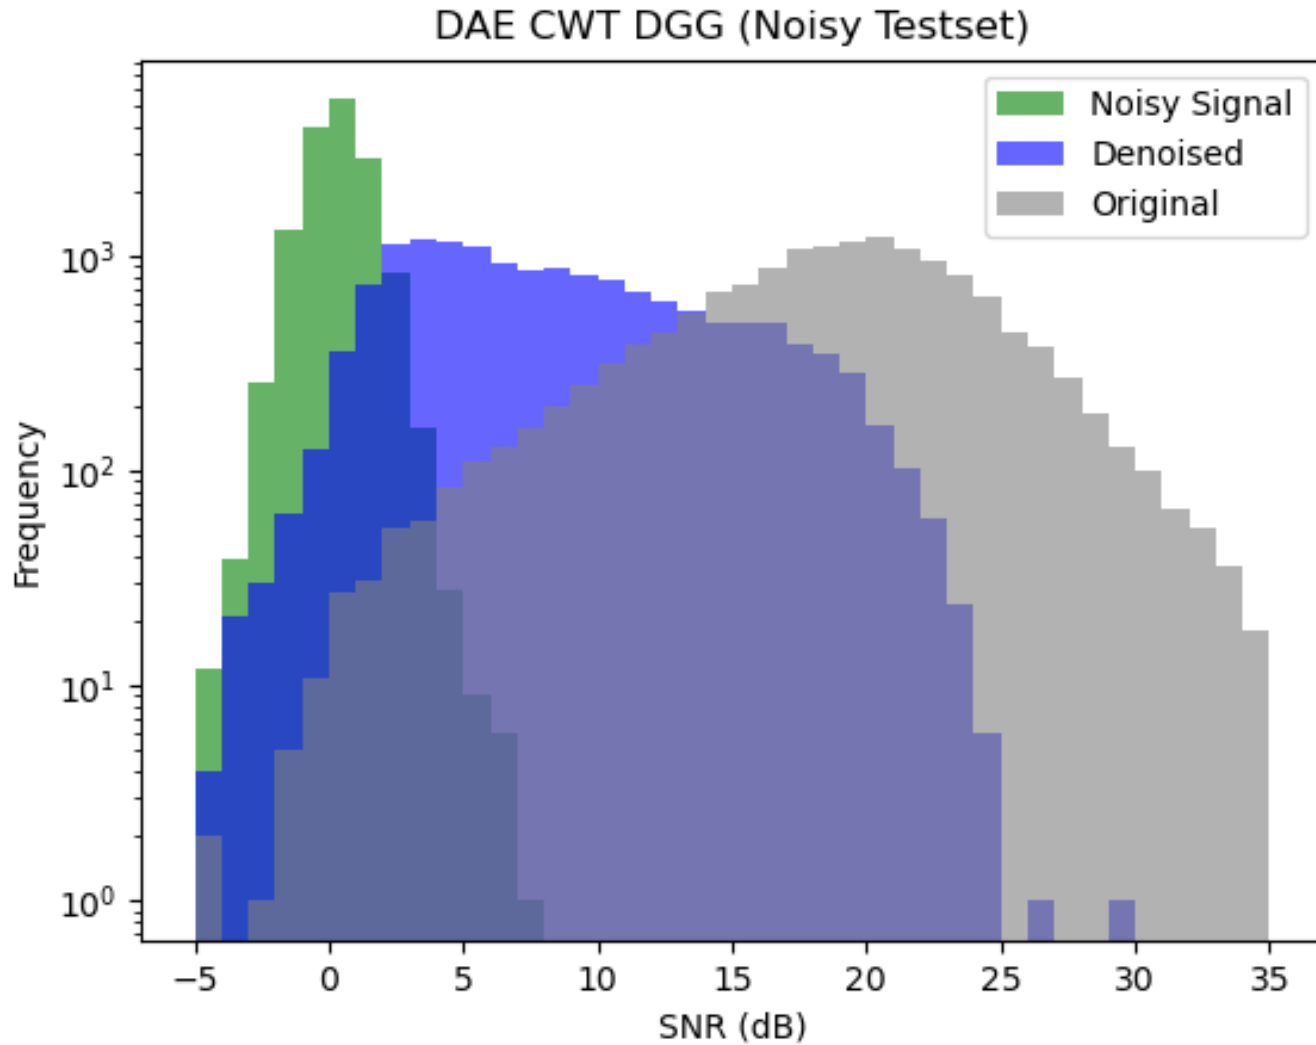
1. Zeit-Frequenz Darstellung vom Signal, Rauschen und verauschten Signal
2. Berechnung der Masking Functions für Signal und Rauschen:

$$M_S(t, f) = \frac{1}{1 + \frac{|N(t, f)|}{|S(t, f)|}}$$
$$M_N(t, f) = \frac{\frac{|N(t, f)|}{|S(t, f)|}}{1 + \frac{|N(t, f)|}{|S(t, f)|}}$$

(Zhu et al, 2019)

3. Eingabe ins neuronale Netzwerk, das dadurch die einzelnen Neuronen / Kernels / Filter anpasst


Ergebnisse




Ergebnisse BAVN | Haltern am See

SNR: 3.01 | SNR Bandpass: 2.5 | SNR Thresh: 8.41 | SNR CWT: 12.9 | SNR STFT: 10.96


Original Data




Bandpass Filter 1-10 Hz




CWT Threshold Denoising








DAE CWT



DAE STFT



Time (s)




Time (s)


Amplitude (m/s)

Ergebnisse BAVN | Haltern am See


Original Data




Bandpass Filter 1-10 Hz




CWT Threshold Denoising








DAE CWT



DAE STFT

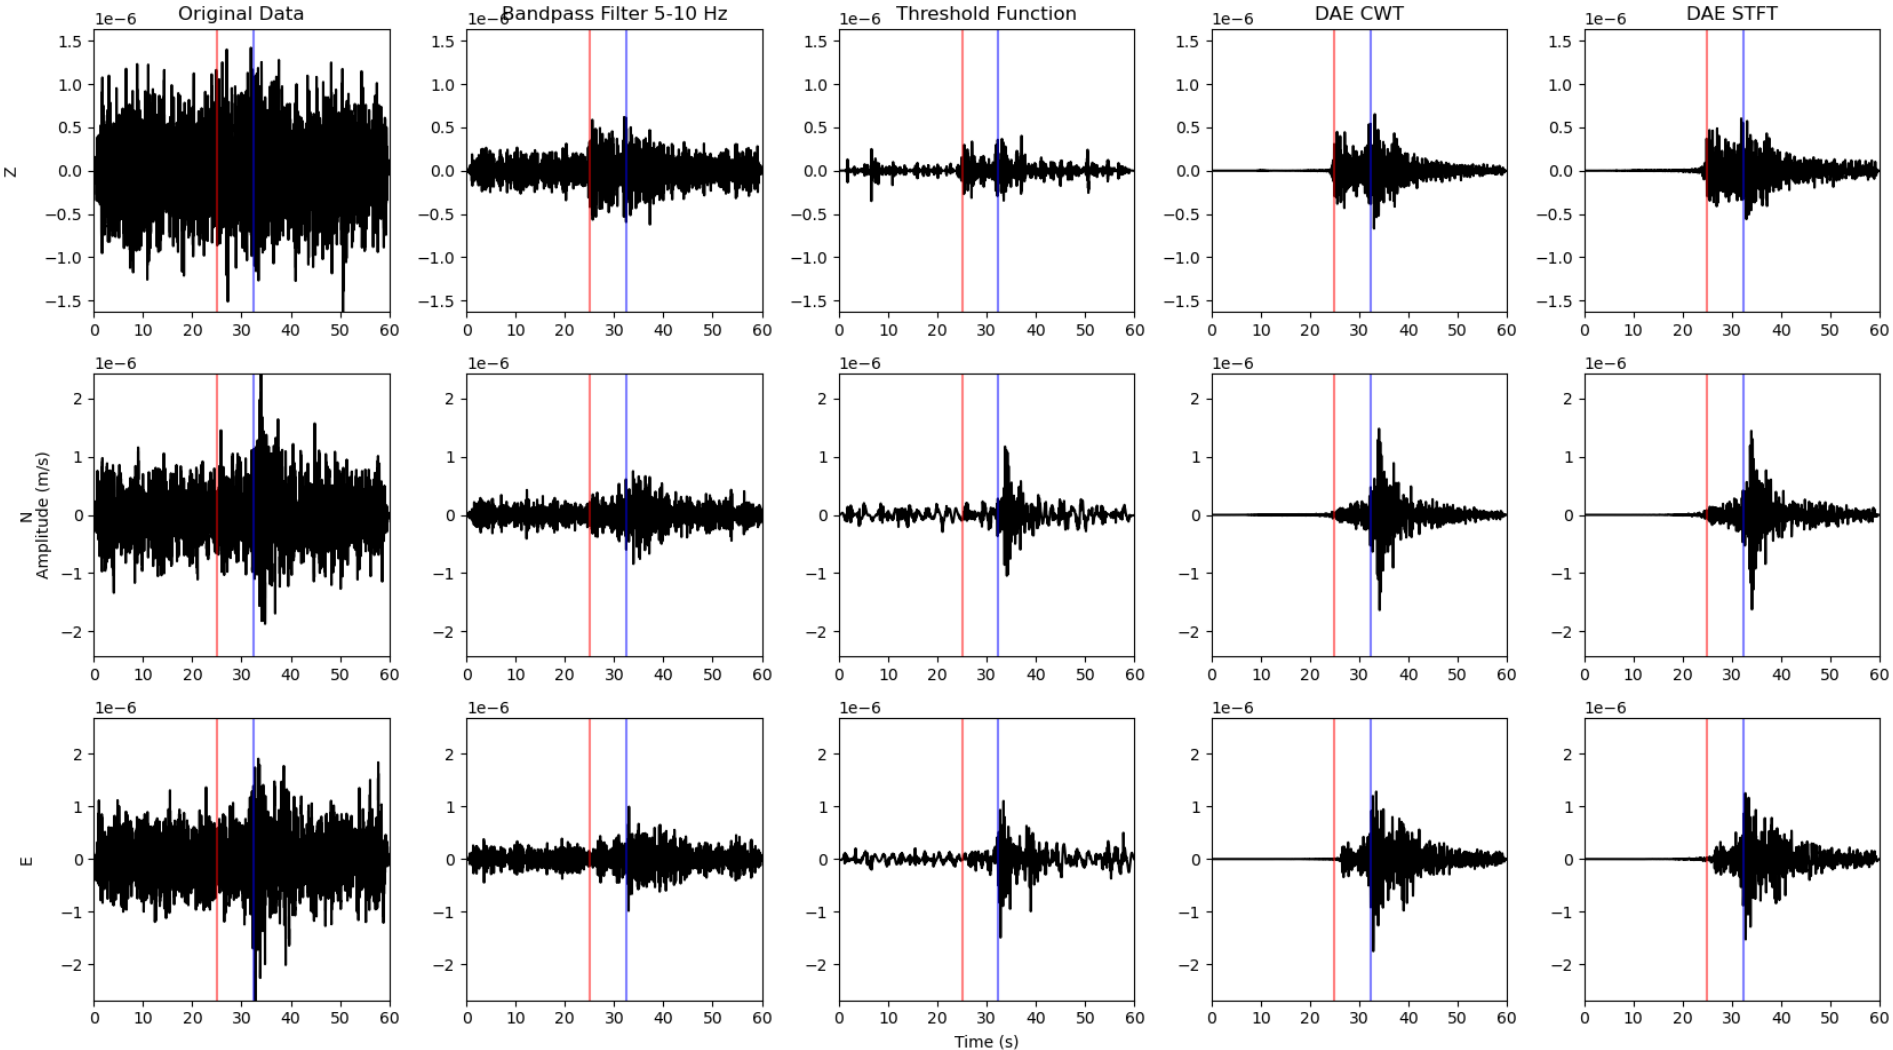


Time (s)





Time (s)

Ergebnisse BAVN | Haltern am See




Ergebnisse BAVN | Haltern am See

RN.BAVN..EHZ




Ergebnisse BAVN | Haltern am See

RN.BAVN..EHZ

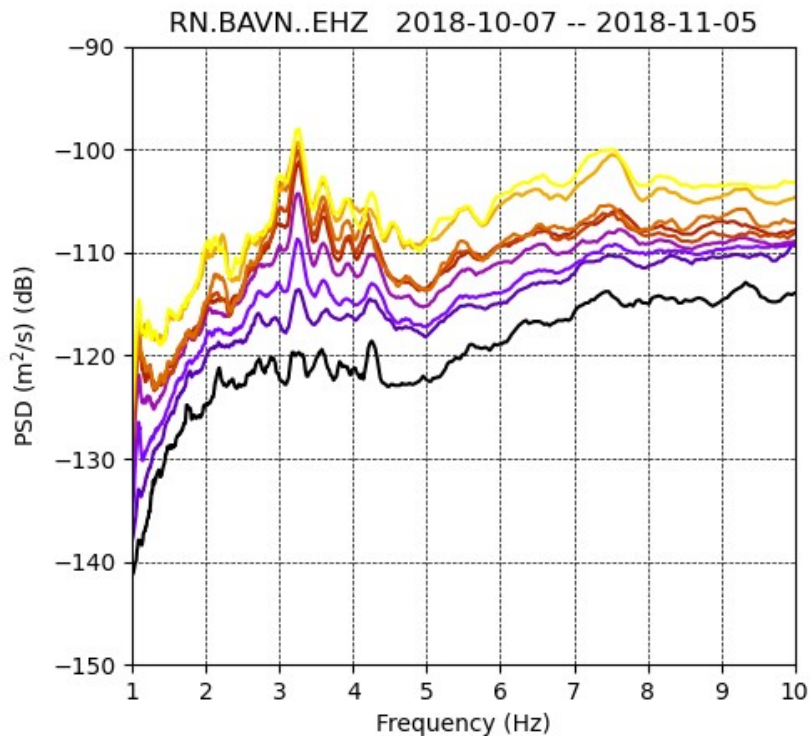


Ergebnisse BAVN | Haltern am See




Ergebnisse BAVN | Haltern am See


Recovered Noise



Recovered Signal



Ergebnisse Gräfenberg Array




Stammler & Ceranna, 2016


Ergebnisse Gräfenberg Array

SNR: 5.01 | SNR Bandpass: 1.57 | SNR Thresh: 15.32 | SNR CWT: 19.67 | SNR STFT: 7.55


Original Data




Bandpass Filter 1-10 Hz




CWT Threshold Denoising








DAE CWT



DAE STFT

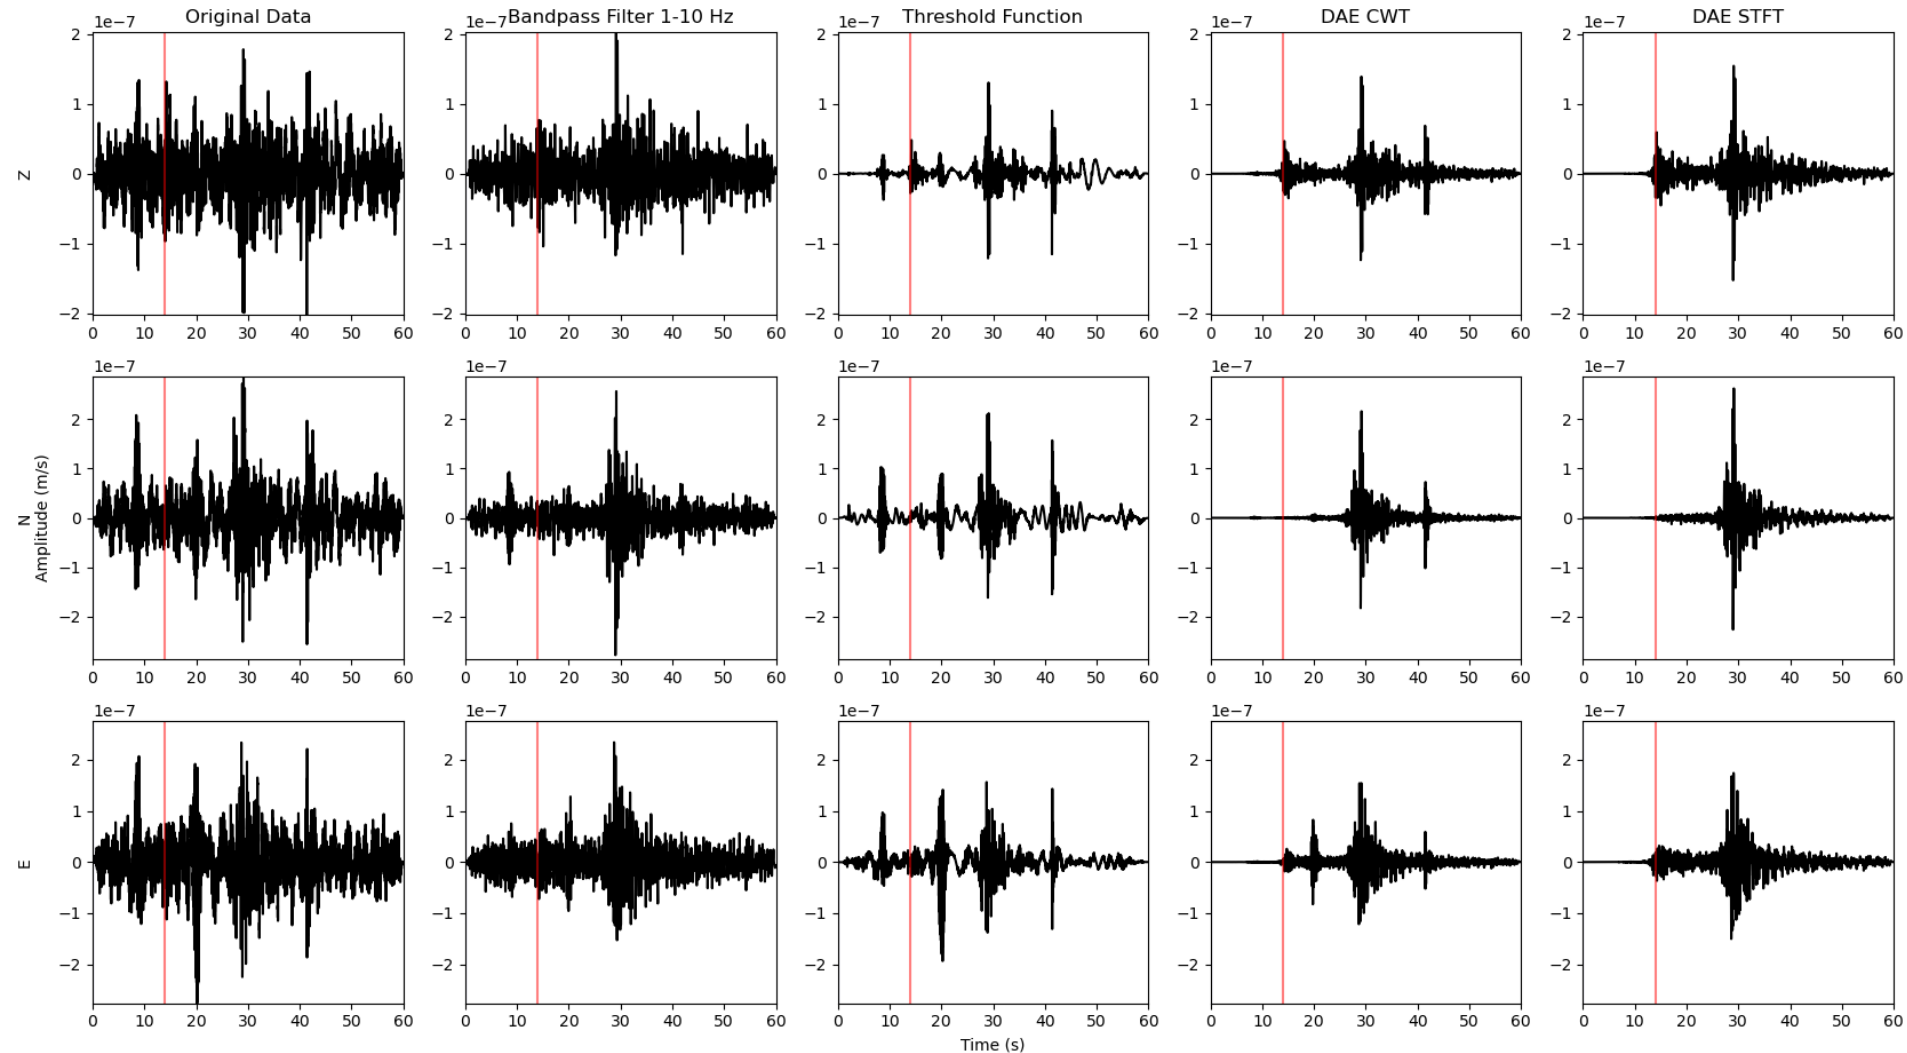


Time (s)



Time (s)

Ergebnisse Gräfenberg Array



Zusammenfassung

- DAE ist etwas Zauberei, aber führt zu den besten Ergebnissen aller getesteten Filtermethoden
- Falls es zu destruktiver Interferenz zwischen WEA und seismischen Signal kommt, kann der DAE das Signal nicht rekonstruieren
- Einfach und schnell anwendbar für Endverbraucher, wenn man ein trainiertes Modell besitzt

Ursprünglicher Arbeitsplan MISS

- Deterministische Vorhersagemethode war nicht realisierbar, da ursprüngliche Hypothese, dass ähnliche Signale an einer WEA zu ähnlichen Signalen an einer entfernten seism. Station führen, nicht bestätigt werden konnte
 - ggf. liegt das auch an der ausgewählten Station?
- Offene Frage: Lassen sich die Signale an einer WEA clustern?
 - Self Organizing Maps (Masterarbeit?)