

# Deteksi Epilepsi Dengan Diskrit Wavelet Transform

*by* Siswandari -

---

**Submission date:** 14-Dec-2023 11:19AM (UTC+0700)

**Submission ID:** 2258561051

**File name:** Deteksi\_Epilepsi\_Dengan\_Diskrit\_Wavelet\_Transform.pdf (584.92K)

**Word count:** 2756

**Character count:** 15891

# Deteksi Epilepsi Dengan Diskrit Wavelet Transform

**Siswandari Noertjahjani**  
Program Studi Teknik Elektro, Universitas Muhammadiyah Semarang  
Email: siswandari@unimus.ac.id

## INFORMASI ARTIKEL

### Histori artikel:

Naskah masuk, 25 Juli 2023  
Direvisi, 10 Agustus 2023  
Diiterima, 10 Agustus Juli 2023

### Kata Kunci:

Epilepsi,  
Normal,  
Energi,  
standar deviasi

## ABSTRAK

### Abstract-

Supporting the diagnosis of epilepsy is to use EEG. However, this step requires a long time and skilled experts. Functions in each model are needed to separate between normal and abnormal signals. Based on these features, EEG signals are identified and classified using Classifiers. The characteristics of the mean, standard deviation and energy are the characteristics used in this study. The electrodes used are a superposition of FP1 and FP2. The extracted signal is based on time-frequency domain characteristics using dwt Daubechies 8 (db8). The ability of the characteristics to distinguish epileptic EEG signals from normal EEG signals was analyzed using the F score feature selection method. The best feature selection results were tested using the Back Propagation Neural Networks (BPNN), K-nearest Neighbor (KNN), Support Vector Machine and Extreme classification algorithms. Learning Machines (ELM). The DWT-based technique with the Extreme Learning Machine classification has an accuracy of 98% at D5 using the standard deviation feature. While the energy characteristic, the highest accuracy is D5 with the same classification and has a lower accuracy.

### Abstrak-

Pendukung diagnosis epilepsi adalah dengan menggunakan EEG. Namun, langkah ini memerlukan waktu yang panjang dan tenaga ahli terampil. Fungsi pada setiap model dibutuhkan untuk memisahkan antara sinyal normal dan abnormal. Berdasarkan fitur tersebut, sinyal EEG diidentifikasi dan diklasifikasikan menggunakan Pengklasifikasi. Ciri mean, standar deviasi dan energi merupakan ciri yang dipakai dalam penelitian ini. Elektroda yang digunakan merupakan superposisi dari FP1 dan FP2. Sinyal yang diekstraks berdasarkan ciri domain waktu frekuensi menggunakan dwt Daubechies 8 (db8). Kemampuan ciri-ciri dalam membedakan sinyal EEG epilepsi dan sinyal EEG normal dianalisa menggunakan metode seleksi ciri F score. Ciri terbaik hasil seleksi diuji menggunakan klasifikasi algoritme Back Propagation Neural Networks (BPNN), K-nearest Neighbor (KNN), Support Vector Machine dan Extreme Learning Machine (ELM). Teknik berbasis DWT dengan klasifikasi Extreme Learning Machine mempunyai akurasi 98 % pada D5 dengan menggunakan ciri standar deviasi. Sedangkan ciri energi, akurasi tertinggi pada D5 dengan klasifikasi yang sama dan mempunyai akurasi yang lebih rendah.

Copyright © 2023 LPPM - STM IKMI Cirebon  
This is an open access article under the CC-BY license

### Penulis Korespondensi:

Siswandari Noertjahjani  
Program studi Teknik Elektro,  
Universitas Muhammadiyah Semarang  
Jl. Kedungmundu Raya No. 18  
SEMARANG, 50273  
Email: siswandari@unimus.ac.id

## 1. Pendahuluan

Sekitar 70% pasien epilepsi dapat disembuhkan, sisanya tidak dapat disembuhkan[1][2]. Kejang epilepsi terus menerus mengakibatkan kematian[3]. Oleh karena itu, pengenalan metode deteksi otomatis serangan epilepsi telah menjadi terobosan selama dua dekade terakhir. Diagnosis otomatis serangan epilepsi tidak hanya akan membantu dokter dengan diagnosis penyakit yang lebih akurat, tetapi juga akan membantu mereka lebih memahami mekanisme di balik penyakit, dan sebagai hasilnya, menghasilkan rencana terprogram untuk perawatan pasien. Epilepsi adalah gangguan otak yang terjadi pada manusia tanpa memandang usia dan digambarkan sebagai kejang[4].

Selain itu, ekstraksi fitur rekaman EEG yang paling menonjol memainkan peran kunci dalam klasifikasi kelainan otak, khususnya aplikasi deteksi kejang. Penelitian tentang deteksi kejang telah dilakukan di daerah temporal dengan menggunakan DWT [5][6][7]. Filter Variable Gaussian dan klasifikasi Fuzzy RBF ELM juga telah dilakukan untuk mendeteksi serangan epilepsi[8]. Pada tahun 2021 penelitian deteksi epilepsi secara otomatis menggunakan DWT dan entropi menghasilkan akurasi 99 % tetapi tidak menyebutkan elektroda mana yang dipakai [9]. Sampai saat ini deteksi epilepsi pada sinyal EEG banyak dilakukan dengan metode linear dan non-linear dengan DWT. Teknik ekstraksi sifat untuk membedakan antara kejang, kejang, dan aktivitas bebas EEG standar bersama dengan algoritme pembelajaran mesin adalah fokus utama dari metode penelitian ini. Metode deteksi kejang otomatis dengan time-frequency analysis menggunakan DWT. Penelitian ini menggunakan metode dekomposisi sinyal EEG berbasis DWT dengan mother wavelet db8. Ekstraksi ciri menggunakan standar deviasi dan energi. Hasil seleksi fitur terbaik menjadi masukan untuk klasifikasi sinyal EEG berdasarkan BPNN, ELM, SVM dan KNN

## 2. Diskrit Wavelet Transform

Pada tahun 1976 ditemukan teori wavelet untuk menguraikan sinyal diskrit. Fungsi dari CWT adalah menganalisis sinyal dasar yang dihubungkan dengan penskalaan melalui transisi yang tidak rumit. . Sebaliknya, Teknik penyaringan digital dipakai DWT untuk mempertahankan representasi parameter waktu dari bentuk digital. Tahapan dari teknik ini terdiri dari meloloskan sinyal untuk dianalisis ke filter pada frekuensi dan skala yang berlainan. Penyaringan itu adalah fungsi dari pemrosesan sinyal. Pada Penskalaan Iterasi Filter diimplementasikan dengan Wavelet. Filter ini

menentukan resolusi sinyal, yaitu jumlah rata-rata detail dalam sinyal, dan rasionya ditentukan oleh upsampling dan downsampling. Untuk menganalisis frekuensi sinyal, diperlukan 2 filter DWT low pass dan high pass. Untuk menganalisis sinyal dalam kawasan frekuensi tinggi digunakan high-pass filter dan kawasan frekuensi rendah memakai low-pass filter[10]. Transformasi wavelet digunakan untuk menganalisis frekuensi yang berbeda-beda. Dalam wavelet dekomposisi ada 2 frekuensi yaitu tinggi dan rendah , yaitu filter high-pass dan low-pass.  $[x(t)]$  dengan fungsi wavelet  $[\psi_{a,b}(t) = 1]$  adalah transformasi wavelet yang dilambangkan sebagai berikut

$$10 \quad W_{\psi}X(a,b) = (x, \psi_{a,b}) \quad (1)$$

$$\psi_{a,b}(t) = |a|^{-\frac{1}{2}} \psi\left(\frac{t-b}{a}\right) \quad (2)$$

Transformasi wavelet diskrit (DWT) didefinisikan sebagai skala diskrit ( $a_j = 2^j$ ) dan waktu ( $b_{j,k} = 2^j k$ ), membagi sinyal menjadi perkiraan, dan koefisien terperinci. Skala Rendah memberikan informasi tentang komponen frekuensi tinggi dan skala tinggi pada frekuensi rendah. Deteksi epilepsi menggunakan wavelet telah dilakukan. Analisis multi-resolusi dan tingkat dekomposisi untuk mendapatkan tingkat resolusi frekuensi yang diperlukan adalah keuntungan dari wavelet. Wavelet Daubechies telah digunakan sebagai mother wavelet untuk transformasi sinyal  $x(n)$ . Wavelet db8 memiliki sifat ortogonal, asimetris, dan biortogonal. Sinyal EEG epilepsi memiliki sifat ortogonalitas dan penyaringan yang efisien. Filter high pass  $g(n)$  dan low pass filter  $h(n)$  dipakai wavelet dengan frekuensi cut off  $h(n)$  dan  $g(n)$  sama dengan seperempat dari frekuensi sampel input sinyal EEG. Pada langkah pertama, sinyal input EEG difilter bersama melalui filter  $h(n)$  dan  $g(n)$ . Hasil keluaran disebut 'perkiraan/ aproksimasi' ( $A_j$ ) dan 'Detail' ( $D_j$ ). Koefisien perkiraan dan terperinci disajikan pada tingkat ( $i^{th}$ ) sebagai berikut:

$$A_i = \frac{1}{\sqrt{M}} \sum_N x(n) \cdot \varphi_{j,k}(n) \quad (3)$$

$$D_i = \frac{1}{\sqrt{M}} \sum_N x(n) \cdot \psi_{j,k}(n) \quad (4)$$

Fungsi skala:

$$\varphi_{j,k}(n) = 2^{-\frac{j}{2}} h(2^{-j}n - k) \quad (5)$$

Fungsi wavelet:

$$\psi_{j,k}(n) = 2^{-\frac{j}{2}}g(2^{-j}n - k) \quad (6)$$

$$\begin{aligned} n &= 0, 1, \dots, M-1; \\ j &= 0, 1, \dots, j-1; \\ k &= 0, 1, \dots, 2^j - 1; \end{aligned}$$

Terdapat lima level frekuensi sinyal EEG, yaitu delta (0,5 sampai 4 Hz), theta (4 sampai 8 Hz), alpha (8 sampai 13 Hz), beta (13 sampai 30 Hz), dan gamma (30 sampai 60 Hz). Untuk dataset sinyal EEG berada dalam kisaran 0–256 Hz dan koefisien D1, D2, D3, D4, D5, D6, dan A6 diekstrak sesuai dengan 128 sampai 256 Hz, 64 sampai 128 Hz, 32 sampai 64 Hz, 16 sampai 32 Hz, 8 sampai 16 Hz, 4 sampai 8 Hz, dan 0 sampai 4 Hz.

### 2.1 Ekstraksi ciri

Ekstraksi fitur adalah bagian mendasar dari analisis sinyal. Sinyal EEG tersegmentasi 3 detik terdiri dari 1280. DWT enam tingkat dengan wavelet Daubechies db8. Fitur statistic mean, standar deviasi dan energi dihitung dari koefisien A6, D1, D2, D3, D4, D5, D6 untuk memberikan diskriminasi antara epilepsi dan normal.

### 2.2 Seleksi ciri Fscore

Setelah proses ekstraksi ciri selesai dilakukan, maka proses berikutnya adalah memilih dan memilah ciri. Seleksi ciri bertujuan untuk mengidentifikasi subset optimal atau suboptimal dari ciri yang paling prediktif atau informatif yang diberikan dataset ciri asli Ekstraksi. Seleksi ciri / fitur merupakan langkah kedua dari metode penelitian. Kemudian hasil ekstraksi fitur diseleksi fiturnya. Pemilihan fitur dapat membantu sistem klasifikasi asli mencapai kinerja prediksi yang lebih baik dan mengurangi biaya komputasi dengan menghapus fitur yang berlebihan. F-Score adalah teknik sederhana namun kuat untuk mengevaluasi kekhasan setiap fitur dalam satu set fitur. Setiap fitur i didefinisikan sebagai:

$$F_i = \frac{(\bar{x}_i^{(+)} - \bar{x}_i)^2 + (\bar{x}_i^{(-)} - \bar{x}_i)^2}{\frac{1}{n_+ - 1} \sum_{k=1}^{n_+} (\bar{x}_{k,i}^{(+)} - \bar{x}_i^{(+)})^2 + \frac{1}{n_- - 1} \sum_{k=1}^{n_-} (\bar{x}_{k,i}^{(-)} - \bar{x}_i^{(-)})^2} \quad (7)$$

$\bar{x}_i$  adalah nilai rata-rata fitur ke-i dari kumpulan data umum, positif dan negatif. Penghitung memberikan perbedaan antara set positif dan negatif, dan penyebut mewakili satu di masing-masing dari dua set. Semakin tinggi F-score, semakin besar kemungkinan fitur ini diskriminatif. Skor-F diurutkan dalam urutan menurun untuk membuat kombinasi fitur yang digunakan untuk pelatihan dan pengujian.

## 2.3 Klasifikasi

### 2.3.1 BPNN

Klasifikasi pada penelitian ini menggunakan BPNN. Masukan jaringan BPNN adalah vektor ciri dimensi waktu dan dimensi waktu frekuensi terpilih dari masing-masing jenis kelas dari sinyal EEG. Output jaringan ada 2, kelas yang terdiri dari kelas 1 merupakan kelompok epilepsi, kelas 2 untuk kelompok normal.

Berdasarkan hal di atas, sebuah jaringan dibentuk dengan jumlah masukan neuron yang berbeda tergantung dari ukuran vektor fitur. Jumlah neuron keluaran sama dengan jumlah kelas yang diharapkan yaitu 2 neuron. Terdapat dua tahapan utama dalam jaringan BPNN yang dibentuk, yaitu tahapan training jaringan dan tahapan klasifikasi sinyal EEG.

### 2.3.2 KNN

Tahapan perhitungan klasifikasi metode K-NN yaitu sebagai berikut:

1. Data latih diambil dari hasil seleksi ciri
2. Data uji diambil dari hasil seleksi ciri
3. Tentukan nilai K
4. Hitung nilai Euclidean Distance

$$d_i = \sqrt{\sum_{1=i}^p (x_{2i} - x_{1i})} \quad (8)$$

$d_i$  = jarak antara objek training dan objek test

$x_1$  = objek test

$x_2$  = objek training

$p$  = dimensi objek

Mengurutkan objek-objek berdasarkan jarak terkecil ke besar


### 2.3.3 Support Vector Machine

SVM berada satu kelas dengan Neural Network dan masuk kedalam supervised learning. Klasifikasi SVM mencari Hyperplane terbaik untuk memisahkan sinyal EEG epilepsi dan normal.

### 2.3.4 Extreme Learning Machine


ELM adalah algoritma pembelajaran yang awalnya dikembangkan. SLFN (Single Layer Feedforward Neural Network) menggantikan propagasi balik. ELM menawarkan proses pembelajaran seribu kali lebih cepat daripada backpropagation, namun dengan kemampuan generalisasi yang lebih besar.

## 3. Hasil dan Pembahasan




Gambar 1. sinyal EEG epilepsi FP12


Gambar 2. Dekomposisi enam level sinyal EEG epilepsi FP12 menggunakan metode DWT (db8).



Gambar 2. Dekomposisi enam level sinyal EEG epilepsi FP12 menggunakan metode DWT (db8).



Gambar 3. sinyal EEG normal FP12



Gambar 4. Dekomposisi enam level sinyal EEG normal FP12 menggunakan metode DWT (db8).

Setelah mengekstraksi dan memilih fitur dari sinyal EEG, langkah selanjutnya adalah menggunakan fitur tersebut sebagai input vektor untuk mengklasifikasikan sinyal EEG normal dan abnormal (epilepsi) menggunakan Back Propagation

Neural Networks (BPNN), K-nearest Neighbor (KNN), Support Vector Machine dan Extreme Learning Machine (ELM).

Tabel 1. Hasil klasifikasi D4 pada ciri standar deviasi

No	Model	Akurasi (%)
1	BPNN	90
2	KNN	85
3	SVM	95
4	ELM	97

Tabel 2. Hasil klasifikasi D5 pada ciri standar deviasi

No	Model	Akurasi (%)
1	BPNN	92
2	KNN	88
3	SVM	95
4	ELM	98

Tabel 3. Hasil klasifikasi D6 pada ciri standar deviasi

No	Model	Akurasi (%)
1	BPNN	88
2	KNN	80
3	SVM	90
4	ELM	90

Tabel 4. Hasil klasifikasi D4 pada ciri energi

No	Model	Akurasi (%)
1	BPNN	88
2	KNN	85
3	SVM	95
4	ELM	97

Tabel 5. Hasil klasifikasi D5 pada ciri energi

No	Model	Akurasi (%)
1	BPNN	90
2	KNN	88
3	SVM	88
4	ELM	97

Tabel 6. Hasil klasifikasi D6 pada ciri energi

No	Model	Akurasi (%)
1	BPNN	87
2	KNN	85
3	SVM	95
4	ELM	96

Penelitian ini bertujuan untuk mengevaluasi kemampuan algoritma DWT untuk deteksi epilepsi. Kanal elektroda sinyal EEG yang digunakan FP12 yang merupakan superposisi dari elektroda FP1 dan FP2. Segmentasi sinyal per kanal elektroda adalah 3 detik. Sinyal epilepsi dan normal didekomposisi menjadi koefisien yang berbeda dengan DWT db8 sehingga terbentuk koefisien Detail1, Detail2, Detail3, Detail4, Detail5, Detail6 dan A6. Pada gambar 1 menunjukkan sinyal EEG epilepsi FP12 dan gambar 2 menunjukkan dekomposisi enam level sinyal EEG epilepsi FP12 menggunakan metode DWT (db8). Sedangkan Pada gambar 3

menunjukkan sinyal EEG normal FP12 dan gambar 2 menunjukkan Dekomposisi enam level sinyal EEG normal FP12 menggunakan metode DWT (db8).

3 koefisien sinyal epilepsi dan normal yang terbentuk D1, D2, D3, D4, D5, D6, A6 kemudian dihitung nilai mean, energi dan standardeviasinya. Secara keseluruhan, terdapat 42 fitur yang diekstrak. Hasil fitur terbaik setelah melalui seleksi ciri F-score adalah vektor fitur standar deviasi D5, standardeviasi D4, energi D5, energi D4, standardeviasi D6, energi D6, standar deviasi D3, standardeviasi D2, energi D3, energi D2, standardeviasi D1, energi D2, mean D3, mean D4, mean D6, mean D5, mean D2, mean D1. Hasil seleksi fitur yang terbaik kemudian diklasifikasi dengan BPNN, KNN, SVM dan ELM yang di tunjukkan pada ciri standar deviasi tabel 1, tabel 2, tabel 3, dan ciri energi tabel 4 dengan D4 , tabel 5 dengan D5 dan tabel 6 dengan D6.

#### 4. Kesimpulan

Paper ini mengusulkan metode Deteksi Epilepsi Dengan Diskrit Wavelet Transform menggunakan Daubechies 8 (db8) metode klasifikasi sinyal EEG menggunakan BPNN, KNN, SVM dan ELM. Penelitian ini tahapan pertama adalah segmentasi sinyal EEG 3 detik kemudian perhitungan ekstraksi ciri mean, standar deviasi dan energi. Untuk pemilihan data masukan klasifikasi, dilakukan seleksi ciri F-score. Dari hasil uji coba, metode klasifikasi ELM dengan D5 mempunyai akurasi yang tinggi pada ciri standardeviasi sehingga bisa dipakai untuk identifikasi penyakit epilepsi berdasarkan sinyal EEG. Kekurangan dari penelitian ini adalah pembagian frekuensi wavelet Detail (D) dan aproksimasi (A), ekstraksi ciri yang tepat. Penelitian ini dapat dikembangkan dengan menggunakan wavelet yang lain db4, segmentasi sinyal yang 2 detik maupun 1 detik.

#### Daftar Pustaka

- [1] R. P. Mcinnis, M. Abubakar, J. Jing, J. J. Halford, F. J. Mateen, and M. B. Westover, "Epilepsy & Behavior Epilepsy diagnosis using a clinical decision tool and artificially intelligent electroencephalography," *Epilepsy Behav.*, vol. 141, p. 109135, 2023, doi: 10.1016/j.yebeh.2023.109135.
- [2] M. Sharma, S. Patel, and U. R. Acharya, "Automated detection of abnormal EEG signals using localized wavelet filter banks," *Pattern Recognit. Lett.*, vol. 133, pp. 188–194, 2020, doi: 10.1016/j.patrec.2020.03.009.
- [3] H. He, X. Liu, and Y. Hao, "A progressive deep wavelet cascade classification model for epilepsy detection," *Artif. Intell. Med.*, vol. 118, no. April, p. 102117, 2021, doi:

- 10.1016/j.artmed.2021.102117.
- [4] E. Tuncer and E. Dog, "Channel based epilepsy seizure type detection from electroencephalography ( EEG ) signals with machine learning techniques," vol. 42, pp. 575–595, 2022, doi: 10.1016/j.bbe.2022.04.004.
- [5] Z. Telatar, "Biomedical Signal Processing and Control Automated temporal lobe epilepsy and psychogenic nonepileptic seizure patient discrimination from multichannel EEG recordings using DWT based analysis," vol. 77, no. May, 2022, doi: 10.1016/j.bspc.2022.103755.
- [6] K. Gadhomi, J. Lina, and J. Gotman, "Clinical Neurophysiology Discriminating preictal and interictal states in patients with temporal lobe epilepsy using wavelet analysis of intracerebral EEG," *Clin. Neurophysiol.*, vol. 123, no. 10, pp. 1906–1916, 2012, doi: 10.1016/j.clinph.2012.03.001.
- [7] H. U. Amin, M. Z. Yusoff, and R. F. Ahmad, "Biomedical Signal Processing and Control A novel approach based on wavelet analysis and arithmetic coding for automated detection and diagnosis of epileptic seizure in EEG signals using machine learning techniques," *Biomed. Signal Process. Control*, vol. 56, p. 101707, 2020, doi: 10.1016/j.bspc.2019.101707.
- [8] A. Harishvijey and J. B. Raja, "Biomedical Signal Processing and Control Automated technique for EEG signal processing to detect seizure with optimized Variable Gaussian Filter and Fuzzy RBFELM classifier," *Biomed. Signal Process. Control*, vol. 74, no. January, p. 103450, 2022, doi: 10.1016/j.bspc.2021.103450.
- [9] A. Zarei and B. M. Asl, "Automatic seizure detection using orthogonal matching pursuit , discrete wavelet transform , and entropy based features of EEG signals," *Comput. Biol. Med.*, vol. 131, no. February, p. 104250, 2021, doi: 10.1016/j.compbiomed.2021.104250.
- [10] S. Raghu, N. Sriraam, Y. Temel, S. Vasudeva, A. Satyanjandas, and P. L. Kubben, "Performance evaluation of DWT based sigmoid entropy in time and frequency domains for automated detection of epileptic seizures using SVM classifier," *Comput. Biol. Med.*, vol. 110, no. December 2018, pp. 127–143, 2019, doi: 10.1016/j.compbiomed.2019.05.016.

# Deteksi Epilepsi Dengan Diskrit Wavelet Transform

## ORIGINALITY REPORT

12%

SIMILARITY INDEX

10%

INTERNET SOURCES

6%

PUBLICATIONS

%

STUDENT PAPERS

## PRIMARY SOURCES

1	<a href="http://repository.ubharajaya.ac.id">repository.ubharajaya.ac.id</a> Internet Source	4%
2	<a href="http://ramauniversityjournal.com">ramauniversityjournal.com</a> Internet Source	2%
3	<a href="http://repository.its.ac.id">repository.its.ac.id</a> Internet Source	1%
4	<a href="http://www.mdpi.com">www.mdpi.com</a> Internet Source	1%
5	<a href="http://www.scribd.com">www.scribd.com</a> Internet Source	1%
6	<a href="http://coek.info">coek.info</a> Internet Source	1%
7	<a href="http://downloads.hindawi.com">downloads.hindawi.com</a> Internet Source	1%
8	<a href="http://www.openarchives.org">www.openarchives.org</a> Internet Source	<1%
9	Siswandari Noertjahjani. "Analisis Tipe Wavelet Coiflets 1 Dan Coiflets 5 Untuk Deteksi Penyakit Epilepsi", Seminar Nasional	<1%



10

Anisha Kumar, Pratishtha Singh, Rajlakshmi Khawas, Priscilla Dinkar Moyya, Mythili Asaithambi. "Automated EEG Analysis for Early Diagnosis of Epilepsy: A Comparative Study to Determine Relative Accuracy of Arithmetic and Huffman Coding Algorithms", 2021 Seventh International conference on Bio Signals, Images, and Instrumentation (ICBSII), 2021

Publication

<1 %

11

M. Deypir, R. Boostani, T. Zoughi. "Ensemble based multi-linear discriminant analysis with boosting and nearest neighbor", Scientia Iranica, 2012

Publication

<1 %

12

Ton Duc Thang University

Publication

<1 %

Exclude quotes  On

Exclude matches  < 1 words

Exclude bibliography  On