

# Aplikasi Transformasi Wavelet dan *Adaptive Neuro-Fuzzy Inference System* (ANFIS) untuk Deteksi P300 dalam Uji Kebohongan Berbasis EGG

Sinantya F. Anindya<sup>a</sup>, Arjon Turnip<sup>b</sup>, Hendi H. Rachmat<sup>c</sup>

<sup>a</sup>Jurusan Teknik Elektro, Institut Teknologi Nasional, Bandung  
E-mail: sinantya.f.anindya@gmail.com

<sup>b</sup>UPT Balai Pengembangan Instrumentasi Lembaga Ilmu Pengetahuan Indonesia, Bandung  
E-mail: arjon.turnip@lipi.go.id

<sup>c</sup>Jurusan Teknik Elektro, Institut Teknologi Nasional, Bandung  
E-mail: hendi.elite@gmail.com

## ABSTRAK

Pada aplikasi elektroensefalogram (EEG) untuk mendeteksi kebohongan, pengetahuan seseorang mengenai suatu informasi diamati melalui kemunculan komponen P300 pada EEG. Komponen P300 memiliki *signal-to-noise ratio* yang rendah sehingga sulit dideteksi melalui pengamatan langsung. Tujuan dari penelitian ini adalah untuk mengevaluasi kinerja ANFIS sebagai sistem pendeteksi P300 dalam uji kebohongan berbasis EEG. Pengujian dilakukan dengan memberikan tiga jenis stimuli pada subyek, yaitu *probe*, *target*, dan *irrelevant*. Selama pengujian, EEG subyek direkam melalui lima kanal, yaitu Fz, Cz, Pz, O1, dan O2. Selanjutnya, sinyal EEG dibersihkan menggunakan koreksi *baseline*, *band-pass filter*, dan *independent component analysis* sehingga menghasilkan EEG dengan frekuensi 0.3-30 Hz. Setelah dibersihkan, fitur-fitur sinyal EEG diekstraksi menggunakan transformasi *wavelet* diskrit Daubechies-4. Hasil ekstraksi fitur pada kanal Cz selanjutnya direduksi menjadi fitur-fitur statistik koefisien *wavelet*, yaitu nilai rata-rata, standar deviasi, *mean absolute value*, dan *average power*. Fitur-fitur tersebut diklasifikasikan menggunakan ANFIS. Hasil klasifikasi menunjukkan kinerja sistem deteksi P300 dengan akurasi 64.27%, sensitivitas 60.56%, *specificity* 66.41%, *positive prediction value* 29.38%, dan *negative prediction value* 87.95%.

## Kata Kunci

ANFIS, deteksi kebohongan, EEG, P300, transformasi *wavelet*.

## 1. PENDAHULUAN

Elektroensefalogram (EEG) merupakan rekaman potensial bioelektrik akibat aktivitas neuron pada otak [1]. EEG memiliki manfaat yang mencakup berbagai bidang, tidak terkecuali dalam bidang penegakan hukum. Salah satu aplikasi EEG pada bidang hukum adalah untuk membantu proses deteksi kebohongan (*lie detection*).

Aplikasi EEG untuk deteksi kebohongan telah diteliti sejak tahun 1990-an sebagai alternatif terhadap poligrafi [2]. Dalam deteksi kebohongan berbasis poligrafi, pengujian dilakukan dengan mengamati respon fisiologis subyek seperti respirasi dan tekanan darah. Metode ini memiliki kelemahan yaitu hasilnya yang mudah dikelabui melalui proses antisipasi (*countermeasure*) dari orang yang diuji; sebagai contoh, subyek dapat mengkonsumsi obat untuk menstabilkan tekanan darah [3]. Berdasarkan permasalahan tersebut, maka EEG diteliti sebagai metode alternatif untuk deteksi kebohongan, dengan dasar pemikiran bahwa sinyal EEG lebih sulit untuk dikelabui dibandingkan respon fisiologis pada poligrafi.


Dalam penelitian terkait aplikasi sinyal EEG dalam deteksi kebohongan, deteksi dilakukan dengan mengamati komponen sinyal EEG yang disebut *event-related potential* (ERP). ERP merupakan potensial yang dihasilkan oleh otak sebagai reaksi terhadap stimulus tertentu. Untuk deteksi kebohongan, komponen ERP yang diamati adalah komponen P300 [1,4-6], yaitu potensial positif yang terjadi kurang lebih 300 ms setelah stimulus diberikan. Secara teoritis, komponen P300 akan muncul saat subyek berusaha mendeteksi informasi yang relevan dengan informasi yang dimiliki dan memiliki tingkat kemunculan yang jarang [6]. Oleh karena itu, P300 menjadi komponen yang umum digunakan untuk mendeteksi kebohongan atau informasi yang disembunyikan oleh subyek yang diuji.

Dalam analisis komponen ERP, terdapat dua hal yang harus diperhatikan, yaitu *signal-to-noise ratio* ERP yang rendah dan waktu kemunculannya yang cenderung tidak tetap [7]; kedua hal ini mengakibatkan ERP sulit diamati secara kasat mata. Salah satu cara untuk mengatasi masalah pertama adalah dengan mengamati rata-rata sinyal yang diperoleh, namun metode ini kurang efektif apabila masalah kedua diperhitungkan. Oleh karena itu, perlu digunakan metode lain untuk mendeteksi keberadaannya apabila rata-rata sinyal tidak

memberikan hasil yang baik. Salah satu metode yang dapat digunakan untuk mengetahui keberadaan ERP adalah dengan menggunakan algoritma klasifikasi. Penelitian ini bertujuan untuk mengamati kinerja *adaptive neuro-fuzzy inference system* (ANFIS) sebagai algoritma klasifikasi untuk deteksi ERP P300, khususnya untuk uji kebohongan.

## 2. METODE PENELITIAN

Uji kebohongan berbasis EEG dalam penelitian ini terdiri atas tahap-tahap seperti yang diilustrasikan pada Gambar 1.



Gambar 1: Diagram alir penelitian deteksi kebohongan berbasis EEG

### 2.1. Eksperimen

#### 2.1.1. Naracoba

Eksperimen diikuti oleh 12 naracoba (10 laki-laki dan 2 perempuan) berusia 19-20 tahun. Semua naracoba tidak pernah mengetahui tentang EEG atau uji kebohongan sebelumnya. Keduabelas naracoba dibagi menjadi dua kelompok yang terdiri atas enam orang, yaitu kelompok “berbohong” (*guilty*) dan “tidak berbohong” (*innocent*). Setiap naracoba akan berpartisipasi dalam skenario uji kebohongan yang akan dijelaskan pada bagian 2.1.2.1.

#### 2.1.2. Persiapan

##### 2.1.2.1. Skenario Eksperimen

Pada penelitian ini, skenario pengujian dirancang berdasarkan metode uji kebohongan *guilty knowledge test* (GKT). Pada GKT, naracoba diberikan berbagai informasi (stimulus) yang terdiri atas tiga kategori yaitu [2]:

1. **Irrelevant** merupakan stimulus yang tidak ada kaitannya sama sekali dengan skenario pengujian yang dilakukan. Idealnya, stimulus ini tidak diketahui oleh semua naracoba.
2. **Target** merupakan stimulus yang diketahui oleh semua naracoba. Saat diberikan jenis stimulus ini, naracoba diperintahkan untuk melakukan tugas

tertentu, misalnya menghitung atau menekan tombol.

3. **Probe** merupakan informasi sensitif yang hanya diketahui oleh naracoba yang berbohong, sedangkan bagi naracoba yang tidak berbohong informasi ini tidak berbeda dengan informasi *irrelevant*.

Dua skenario uji kebohongan dirancang dalam penelitian ini. Skenario pertama terdiri atas satu stimulus target dan dua stimuli *probe*, sedangkan skenario kedua terdiri atas dua stimuli target dan satu stimulus *probe*. Selain itu, masing-masing skenario juga memiliki tiga stimuli *irrelevant*. Setiap stimuli merupakan foto yang ditampilkan secara acak dengan frekuensi kemunculan yang berbeda-beda. Informasi mengenai frekuensi kemunculan setiap stimuli pada kedua skenario dapat diamati pada Tabel 1 dan 2.

Tabel 1: Frekuensi kemunculan stimuli pada skenario 1

Kelompok	Jumlah Stimuli	Jumlah kemunculan/ stimulus	Jumlah kemunculan total
Probe	2	7	14
Target	1	6	6
Irrelevant	3	20	60

Tabel 2: Frekuensi kemunculan stimuli pada skenario 2

Kelompok	Jumlah Stimuli	Jumlah kemunculan/ stimulus	Jumlah kemunculan total
Probe	1	6	6
Target	2	7	14
Irrelevant	3	20	60

Pada setiap stimuli, rentang-waktu tertentu dialokasikan untuk mengamati reaksi naracoba pada sinyal EEG yang direkam, yaitu:

1. **Pra-stimulus** merupakan waktu yang dialokasikan sebagai *baseline* untuk mengamati perubahan sinyal EEG sebelum dan sesudah stimulus ditampilkan. Dalam penelitian ini, durasi pra-stimulus yang dialokasikan adalah 300 ms.
2. **Presentasi stimulus** yang berdurasi 700 ms.
3. **Pascastimulus** merupakan rentang waktu untuk mengamati perubahan yang terjadi pada sinyal EEG. Durasi pascastimulus adalah 1000 ms.
4. Jeda sebelum stimulus berikutnya ditampilkan. Durasi jeda yang dialokasikan adalah 1300 ms.

Komponen P300 diamati pada rentang pascastimulus. Idealnya, komponen P300 yang dihasilkan saat naracoba diberikan stimuli *irrelevant* memiliki amplitudo yang lebih kecil dibandingkan saat diberikan stimuli target dan/atau *probe*.

### 2.1.2.2. Pelatihan Naracoba

Sebelum pengujian, keduabelas naracoba dilatih mengenai prosedur percobaan, antara lain informasi yang harus dikenali berdasarkan skenario pengujian yang dipilih, respon yang harus diberikan saat melihat ketiga jenis stimuli, dan hal-hal yang sebaiknya tidak dilakukan selama pengujian. Naracoba pada kelompok “berbohong” diminta untuk mempelajari stimuli target dan *probe*, sedangkan naracoba yang “tidak berbohong” hanya perlu mempelajari stimuli target. Terdapat dua respon yang harus diberikan, yaitu “tahu” dan “tidak tahu”; naracoba pada kelompok “berbohong” diminta untuk merespon seolah-olah tidak mengetahui informasi jenis *probe*. Terakhir, naracoba diminta untuk mengurangi aktivitas yang dapat menyebabkan terjadinya artefak (*noise*) pada sinyal EEG, yaitu bergerak, berkedip, dan duduk dalam posisi tegang.

### 2.1.3. Akuisisi Sinyal EEG

Setelah pelatihan, naracoba berpartisipasi dalam skenario uji kebohongan yang telah ditentukan. Pengujian dilakukan selama kurang lebih lima menit untuk setiap naracoba. Untuk setiap stimulus yang ditampilkan, naracoba harus merespon dengan menekan salah satu dari dua tombol yang diberikan, yaitu tombol merah (“tidak tahu”) dan hijau (“tahu”). Proses uji kebohongan berbasis EEG dapat diamati pada Gambar 2.



Gambar 2: Proses uji kebohongan berbasis EEG

Selama pengujian, sinyal EEG naracoba direkam dengan frekuensi *sampling* sebesar 500 Hz. Sinyal direkam menggunakan elektroda timah yang ditempatkan pada lima kanal pada area *frontal* (Fz), *central* (Cz), *parietal* (Pz), dan *occipital* (O1 dan O2); komponen P300 umumnya dapat diamati pada tiga kanal pertama. Kelima kanal tersebut dihubungkan dengan kanal referensi A1 dan A2 yang dipasang pada telinga naracoba; kanal Fz, Pz, dan O1

dihubungkan dengan kanal A1, sedangkan kanal Cz dan O2 dihubungkan dengan kanal A2.

## 2.2. Pengolahan Data

Setelah proses akuisisi sinyal selesai, sinyal EEG yang diperoleh diolah menggunakan perangkat lunak MATLAB. Dalam penelitian ini, hanya fitur-fitur sinyal dari kanal Cz yang akan diekstraksi dan diklasifikasikan. Pemilihan kanal Cz dilakukan berdasarkan pengamatan terhadap impedansi kanal tempat kemunculan P300 yang paling rendah pada semua naracoba.

### 2.2.1. Pra-Pemrosesan

Saat diakuisisi, sinyal yang diperoleh terkontaminasi oleh artefak yang berasal dari berbagai sumber, antara lain sinyal gerakan mata (EOG), sinyal gerakan otot (EMG), dan *noise* yang berasal dari tegangan jala-jala. Fungsi pra-pemrosesan adalah menghilangkan artefak yang berasal dari sumber-sumber tersebut. Selain itu, pra-pemrosesan juga berfungsi membatasi rentang frekuensi sinyal EEG yang hendak diamati. Dalam penelitian ini, pra-pemrosesan sinyal EEG dilakukan menggunakan *toolbox* FieldTrip [8].

#### 2.2.1.1. Koreksi *Baseline*

Langkah pertama pra-pemrosesan yang dilakukan dalam penelitian ini adalah koreksi *baseline*. Koreksi *baseline* berfungsi untuk menghilangkan *offset* yang terjadi pada sinyal. *Offset* sinyal dapat terjadi akibat penguatan pada *amplifier*, variasi temperatur, dan kontak elektroda dengan kulit kepala naracoba yang buruk sehingga mengakibatkan pergeseran *baseline* [9].

#### 2.2.1.2. *Band-Pass Filter*

Setelah koreksi *baseline*, langkah kedua adalah mengaplikasikan *band-pass filter* untuk membatasi frekuensi sinyal. Dalam penelitian ini, rentang frekuensi sinyal yang hendak diamati adalah 0.3-30 Hz; hal ini disebabkan oleh kemunculan komponen P300 yang cenderung terjadi pada rentang frekuensi yang dipilih [4]. Sinyal EEG difilter secara digital menggunakan filter IIR orde 4; konfigurasi filter tersebut merupakan konfigurasi *default* dari filter yang disertakan pada *toolbox* FieldTrip.

#### 2.2.1.3. *Re-referencing*

Setelah sinyal EEG difilter, langkah selanjutnya adalah mengganti kanal referensi sinyal atau *re-referencing*. Pada penelitian uji kebohongan berbasis EEG terdahulu [4-6], sinyal EEG direkam dengan menggunakan referensi jenis *linked-ear*, yaitu jenis referensi yang menggabungkan kanal A1 dan A2. Penggantian kanal referensi dilakukan agar hasil penelitian ini dapat dibandingkan dengan hasil-hasil penelitian terdahulu.

#### 2.2.1.4. Independent Component Analysis (ICA)

ICA [10] merupakan metode pemisahan sinyal yang telah tercampur dengan sinyal lainnya yang tidak diketahui sumbernya. Pada saat sinyal EEG direkam melalui elektroda di kulit kepala, sinyal yang diperoleh merupakan hasil superposisi berbagai sinyal, baik potensi yang berasal dari aktivitas berbagai neuron pada otak maupun sumber eksternal (artefak). Metode ICA digunakan untuk memisahkan komponen-komponen EEG yang independen secara statistik dan menolak komponen-komponen yang mengakibatkan terjadinya artefak [11].

Secara matematis, sinyal EEG  $x$  merupakan suatu matriks berukuran  $m \times n$ ;  $m$  merupakan jumlah kanal sinyal EEG dan  $n$  merupakan jumlah sampel. Sinyal  $x$  merupakan hasil perkalian antara sinyal EEG asli  $s$  dan sinyal noise  $A$ . Fungsi dari ICA adalah mengembalikan matriks  $s$ . Isi  $s$  tidak diketahui sehingga diperlukan matriks lain yang untuk memisahkan  $s$ , yaitu *unmixing matrix*  $W$ . Seperti matriks  $s$ , matriks  $W$  awalnya tidak diketahui. Untuk menemukan matriks  $W$  yang optimal dapat digunakan berbagai algoritma. Dalam penelitian ini, algoritma yang digunakan adalah maksimisasi informasi menggunakan *neural network* oleh Bell dan Sejnowski [12].

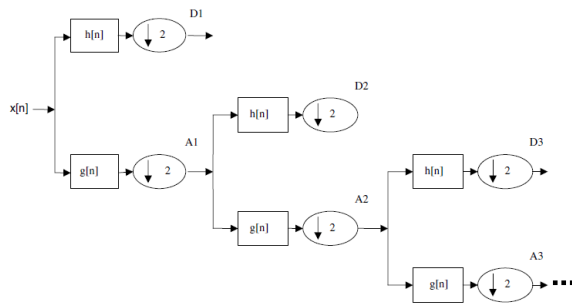
### 2.2.2. Ekstraksi dan Reduksi Fitur

#### 2.2.2.1. Transformasi Wavelet

Dalam penelitian ini, ekstraksi fitur sinyal dilakukan menggunakan transformasi *wavelet* diskrit. Transformasi *wavelet* merupakan metode pemrosesan sinyal dengan memecah sinyal yang dianalisis menjadi sinyal-sinyal yang lebih kecil (*wavelet*) untuk mengamati perubahan pada sinyal. Analisis *wavelet* dilakukan dengan melakukan translasi (*shifting*) dan kontraksi (*scaling*) sebuah sinyal yang disebut *mother wavelet* [13].

Dalam aplikasi transformasi *wavelet* untuk sinyal EEG, terdapat berbagai jenis *mother wavelet* yang dapat digunakan sesuai kebutuhan analisis yang dilakukan, misalnya *quadratic B-spline* [4,5] dan Daubechies-4 [14]. Penelitian ini menggunakan *mother wavelet* jenis Daubechies-4 untuk mengekstraksi fitur sinyal berupa koefisien-koefisien *wavelet*. Jenis *mother wavelet* tersebut dipilih karena dianggap mampu merepresentasikan perubahan pada sinyal EEG akibat kemunculan komponen P300 [14].

Transformasi *wavelet* menghasilkan informasi berupa aproksimasi dan detail dari sinyal yang dianalisis. Setiap aproksimasi dan detail sinyal merepresentasikan rentang frekuensi tertentu. Proses dekomposisi sinyal menjadi detail dan aproksimasi diilustrasikan pada Gambar 3.



Gambar 3: Proses dekomposisi sinyal menggunakan transformasi *wavelet* diskrit

Dalam penelitian ini, sinyal EEG diolah menggunakan transformasi *wavelet* jenis Daubechies-4 sebanyak tujuh kali sehingga diperoleh aproksimasi dan detail sinyal dengan rentang frekuensi yang dijelaskan pada Tabel 3.

Tabel 3: Rentang frekuensi aproksimasi dan detail hasil transformasi *wavelet* ( $F_s=500$  Hz)

Kelompok/ Sub-band	Rentang frekuensi (Hz)
Detail 1 (D1)	125-250
Aproksimasi 1 (A1)	0-125
D2	62.5-125
A2	0-62.5
D3	31.25-62.5
A3	0-31.25
D4	15.625-31.25
A4	0-15.625
D5	7.8-15.625
A5	0-7.8
D6	3.9-7.8
A6	0-3.9
D7	1.95-3.9
A7	0-1.95

### 2.2.2.2. Fitur Statistik

Saat fitur-fitur sinyal diekstraksi, tidak semua fitur mampu memberikan informasi yang relevan mengenai sinyal yang dianalisis, khususnya apabila fitur yang diekstraksi memiliki jumlah yang besar. Kedua faktor tersebut dapat mengakibatkan kinerja sistem klasifikasi yang buruk sehingga fitur yang diperoleh perlu direduksi. Dalam penelitian ini, fitur-fitur sinyal berupa koefisien-koefisien *wavelet* akan direduksi dengan menghitung nilai statistik yang terdiri atas parameter-parameter berikut [14,17]:


1. Rata-rata (*mean*) koefisien *wavelet* pada setiap *sub-band*.
2. Standar deviasi koefisien *wavelet* setiap *sub-band*.
3. Rata-rata nilai absolut (*mean absolute value*) koefisien *wavelet* per *sub-band*.
4. Daya rata-rata (*average power*) dari nilai absolut setiap koefisien *wavelet* per *sub-band*.

Dikarenakan sinyal EEG telah melalui proses *band-pass filter* sebelumnya, fitur-fitur sinyal yang dianggap memiliki informasi relevan terletak pada frekuensi 0.3-30 Hz. Oleh karena itu, proses reduksi fitur hanya akan dilakukan pada koefisien-koefisien *wavelet* pada *sub-band* A7, D7, D6, D5, dan D4.

### 2.2.3. Klasifikasi Fitur

#### 2.2.3.1. Adaptive Neuro-Fuzzy Inference System

*Adaptive neuro-fuzzy inference system* (ANFIS) merupakan sistem pembelajaran mesin yang menggabungkan kemampuan pembelajaran sistem *adaptive network* dengan aproksimasi sistem *fuzzy*. Sistem ini terdiri atas sistem *fuzzy* model Sugeno yang dilatih menggunakan *adaptive network*. Melalui prosedur pembelajaran hibrida tersebut, sistem dapat dimodelkan meskipun ketersediaan pengetahuan ahli tidak terpenuhi [15,17]. Arsitektur sistem ANFIS dapat diamati pada Gambar 4.



Gambar 4: Arsitektur sistem ANFIS

Suatu sistem ANFIS terdiri atas lima lapisan yaitu:

1. Lapisan pertama merupakan lapisan input tempat fungsi keanggotaan input didefinisikan. Lapisan

ini bersifat adaptif.

- Lapisan kedua merupakan lapisan tetap (*fixed*) yang berisi fungsi untuk menentukan bobot dari aturan-aturan *fuzzy* yang ditetapkan. Aturan-aturan ini didasarkan pada model fuzzy Takagi-Sugeno orde pertama dengan contoh sebagai berikut:

Jika ( $x = A_1$ ) dan ( $y = B_1$ ) maka ( $f_1 = p_1x + q_1y + r_1$ )

Jika ( $x = A_2$ ) dan ( $y = B_2$ ) maka ( $f_2 = p_2x + q_2y + r_2$ )

- Lapisan ketiga merupakan lapisan tetap yang berfungsi untuk menormalisasi bobot yang diperoleh dari lapisan kedua.
- Lapisan keempat merupakan lapisan adaptif yang berisi hasil perkalian dari bobot yang telah dinormalisasi dengan aturan *fuzzy* terkait.
- Lapisan terakhir dari arsitektur ANFIS adalah lapisan *output*. Pada lapisan ini, semua *output* dari lapisan keempat dijumlahkan sehingga menghasilkan nilai *output* akhir dari sistem.

### 2.2.3.2. Desain Sistem Deteksi P300

Dalam penelitian ini, ANFIS digunakan sebagai sistem pendeteksi komponen P300 berdasarkan fitur-fitur yang telah diekstraksi sebelumnya. Untuk mendesain sistem tersebut, data hasil ekstraksi fitur yang diperoleh dibagi menjadi tiga kelompok, yaitu data *training*, data validasi, dan data pengujian. Data tersebut selanjutnya digunakan untuk desain sistem menggunakan Fuzzy Logic Toolbox pada MATLAB. Desain sistem berbasis ANFIS terdiri atas tiga langkah yaitu:

- Definisi sistem *fuzzy* awal menggunakan ANFIS menggunakan data *training*.
- Melatih sistem *fuzzy* awal menggunakan data *training* dan validasi. Hasil *training* dibandingkan dengan hasil validasi untuk menghindari terjadinya *overfitting* sistem.
- Pengujian sistem.

Hasil pengujian selanjutnya dibandingkan dengan *output* sistem yang seharusnya. Berdasarkan hasil yang diperoleh, kinerja sistem dapat diamati melalui parameter-parameter berikut [16]:

- Akurasi (*Acc*)

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

- Sensitivitas (*Sens*)

$$Sens = \frac{TP}{TP + FN} \quad (2)$$

- Specificity* (*Spec*)

$$Spec = \frac{TN}{TN + FP} \quad (3)$$

- Positive prediction value* (PPV)

$$PPV = \frac{TP}{TP + FP} \quad (4)$$

- Negative prediction value* (NPV)

$$NPV = \frac{TN}{TN + FN} \quad (5)$$

dengan:

**TP:** data stimulus “diketahui” yang terklasifikasi sebagai “diketahui”

**TN:** data stimulus “tidak diketahui” yang terklasifikasi sebagai “tidak diketahui”

**FP:** data stimulus “tidak diketahui” yang terklasifikasi sebagai “diketahui”

**FN:** data stimulus “diketahui” yang terklasifikasi sebagai “tidak diketahui”

## 3. HASIL PENELITIAN

Bagian ini menjelaskan hasil penelitian yang diperoleh. Dikarenakan penelitian ini difokuskan pada proses transformasi *wavelet* dan klasifikasi menggunakan ANFIS, makalah ini hanya hasil dari ekstraksi dan klasifikasi fitur.

### 3.1. Hasil Ekstraksi dan Reduksi Fitur

Ekstraksi fitur sinyal EEG dalam dilakukan menggunakan transformasi *wavelet* diskrit jenis Daubechies-4. Hasil dari proses ini adalah koefisien-koefisien *wavelet* yang diperoleh dari proses *scaling* dan *shifting* pada sinyal EEG. Untuk setiap segmen sinyal pascastimulus dengan durasi 1000 ms, transformasi *wavelet* yang dilakukan menghasilkan koefisien-koefisien *wavelet* sebagai berikut:

Tabel 4: Hasil transformasi *wavelet* untuk segmen pascastimulus ( $F_s=500$  Hz)

Sub-band	Jumlah koefisien	Durasi per koefisien (ms)
A1	253	3.95
D1	253	3.95
A2	130	7.69
D2	130	7.69
A3	68	14.71
D3	68	14.71
A4	37	27.03
D4	37	27.03
A5	22	45.45
D5	22	45.45
A6	14	71.43
D6	14	71.43
A7	10	100
D7	10	100

Pada Tabel 4, dapat diamati bahwa proses transformasi *wavelet* menghasilkan jumlah koefisien yang besar. Jumlah data yang besar akan mengakibatkan kinerja sistem klasifikasi fitur yang buruk, baik selama proses pelatihan maupun pengujian sistem. Oleh karena itu, koefisien-koefisien *wavelet* yang diperoleh harus direduksi sebelum digunakan untuk proses klasifikasi. Berdasarkan rentang frekuensi sinyal yang diamati, koefisien-koefisien *wavelet* yang akan direduksi dan digunakan untuk klasifikasi fitur harus terletak dalam *sub-band* pada frekuensi 0.3-30 Hz. *Sub-band* yang termasuk dalam rentang frekuensi tersebut antara lain A7, D7, D6, D5, dan D4.

Dalam penelitian ini, reduksi fitur dilakukan dengan menghitung statistik dari koefisien-koefisien *wavelet* pada setiap *sub-band* yang dipilih. Terdapat empat parameter statistik yang dihitung, yaitu nilai rata-rata (*mean*) koefisien *wavelet*, standar deviasi (SD), nilai absolut rata-rata (MAV), dan daya rata-rata (AP). Lima *sub-band* dipilih untuk proses klasifikasi sehingga jumlah fitur yang dihasilkan setelah reduksi adalah 20. Contoh dari hasil proses reduksi fitur dapat diamati pada Tabel 5.

Tabel 5: Hasil reduksi koefisien wavelet dari data Naracoba #1 (segmen target #3)

Parameter	A7	D7	D6	D5	D4
Mean	1.5	0.15	0.47	-0.07	0.03
SD	6.41	1.56	1.11	0.79	0.46
MAV	5.4	1.1	0.97	0.58	0.39
AP	39.1	2.19	1.38	0.61	0.21

### 3.2. Hasil Klasifikasi Fitur

Hasil reduksi fitur selanjutnya digunakan untuk klasifikasi menggunakan ANFIS. Sebelum sistem klasifikasi dibentuk, data yang diperoleh dibagi menjadi tiga kelompok yaitu:


Tabel 6: Pengelompokan data untuk pembentukan sistem klasifikasi

Kelompok	Data Naracoba
Training	1, 4, 7, 8 (target, <i>irrelevant</i> )
Validasi	2, 5, 9, 10 (target, <i>irrelevant</i> )
Pengujian	3, 6, 11, 12 (target, <i>irrelevant</i> ) 1-12 ( <i>probe</i> )


Setelah dikelompokkan, data digunakan untuk membentuk sistem deteksi P300 menggunakan ANFIS. Keduapuluh fitur dari setiap data naracoba digunakan sebagai *input* sistem, sedangkan *output* sistem dinyatakan dalam 0 dan 1. Nilai 0 menyatakan bahwa naracoba **tidak mengetahui** stimulus yang diberikan, sedangkan 1 menyatakan bahwa naracoba

**mengetahui** stimulus tersebut. Data *input* dan *output* pada setiap kelompok disimpan dalam bentuk matriks untuk pembentukan sistem *fuzzy* awal.

Setelah sistem *fuzzy* awal dibentuk, sistem dilatih menggunakan ANFIS berdasarkan parameter yang telah ditentukan. Selain *output* yang dihasilkan, grafik fungsi keanggotaan sistem dapat digunakan untuk mengamati kualitas sistem yang dibentuk. Contoh grafik fungsi keanggotaan dari sistem yang diperoleh diilustrasikan pada Gambar 5 dan Gambar 6.



Gambar 5: Grafik fungsi keanggotaan sebelum training (sub-band D6, parameter *mean*)



Gambar 6: Grafik fungsi keanggotaan sesudah training (sub-band D6, parameter *mean*)

Pada Gambar 5 dan Gambar 6, dapat diamati bahwa fungsi-fungsi keanggotaan yang dihasilkan saling menutupi satu sama lain (*overlapping*); hal ini mengindikasikan kualitas sistem yang kurang baik. Terbentuknya fungsi-fungsi keanggotaan yang saling menutupi diakibatkan oleh data *input* yang memiliki nilai saling berdekatan meskipun menghasilkan *output* yang berbeda.

Berdasarkan hasil klasifikasi yang diperoleh, kinerja sistem deteksi P300 dapat dihitung. Hasil perhitungan parameter kinerja sistem deteksi P300 pada penelitian ini dapat diamati pada Tabel 7.

Tabel 7: Kinerja sistem deteksi P300 secara keseluruhan

Parameter	Nilai (%)
Akurasi	64.27
Sensitivitas	60.56
Specificity	66.41
PPV	29.38
NPV	87.95

## 4. DISKUSI

Berdasarkan hasil yang diperoleh, hasil yang diperoleh masih jauh lebih rendah dibandingkan beberapa penelitian deteksi kebohongan berbasis EEG yang telah dilakukan sebelumnya. Pada penelitian yang dilakukan Abootalebi dkk. [4], sistem deteksi kebohongan yang dihasilkan memiliki akurasi 74%-86%. Pada penelitian oleh Gao dkk. [5], sistem memiliki sensitivitas terhadap data non-P300 sebesar 96.11% dan *specificity* terhadap data P300 sebesar 96.05%. Kedua penelitian tersebut menggunakan transformasi *wavelet* untuk klasifikasi fitur, namun reduksi fitur dilakukan melalui proses seleksi. Hasil seleksi yang diperoleh merupakan koefisien-koefisien yang dianggap merepresentasikan aktivitas komponen P300 dengan baik.

Hal yang perlu dipertimbangkan dari penelitian ini adalah prosedur akuisisi sinyal EEG yang tidak sempurna. Pada data sinyal EEG yang diperoleh, *timing* stimulus cenderung tidak akurat sehingga apabila terjadi kesalahan segmentasi maka komponen P300 tidak akan muncul pada segmen yang dianalisis. Selain itu, dalam penelitian ini tidak digunakan kanal khusus untuk merekam artefak yang terjadi. Hal ini mengakibatkan artefak pada rentang frekuensi yang diamati tidak dapat dideteksi dan dihilangkan.

## 5. KESIMPULAN DAN SARAN

### 5.1. Kesimpulan

Dalam penelitian ini, ANFIS digunakan untuk mendeteksi komponen P300 dalam uji kebohongan berbasis EEG. Berdasarkan hasil yang diperoleh, sistem pendeteksi komponen P300 memiliki akurasi sebesar 64.27%, sensitivitas 60.56%, *specificity* 66.41%, PPV 29.38%, dan NPV 87.95%.

### 5.2. Saran

Saran-saran berikut diberikan dengan harapan dapat meningkatkan hasil penelitian yang akan datang:

1. Menggunakan perangkat yang memungkinkan sinkronisasi antara perangkat presentasi stimuli dengan perangkat akuisisi sinyal EEG untuk meminimisasi kemungkinan hilangnya komponen P300 akibat kesalahan segmentasi.
2. Menggunakan kanal tambahan untuk merekam artefak, khususnya artefak akibat gerakan mata dan gerakan otot.

3. Mereduksi hasil ekstraksi fitur menggunakan algoritma untuk proses seleksi, misalnya algoritma genetik.

## UCAPAN TERIMA KASIH

Penelitian ini merupakan bagian dari program kerja praktik (KP) yang dilaksanakan di UPT Balai Pengembangan Instrumentasi LIPI Bandung. Penulis berterima kasih kepada semua staf UPT BPI LIPI dan sukarelawan percobaan yang turut berpartisipasi dalam penelitian ini.

## DAFTAR PUSTAKA

- [1] L. Cromwell, F.J. Weibell, E.A. Pfeiffer, dan L.B. Usselman, *Biomedical Instrumentation and Measurements*. New Jersey: Prentice-Hall, Inc., 1973.
- [2] L.A. Farwell dan E. Donchin, "The Truth Will Out: Interrogative Polygraphy ("Lie Detection") with Event-Related Brain Potentials", *Psychophysiology*, vol. 28, no. 5, pp. 531–547, 1991.
- [3] L. Saxe, D. Dougherty, dan T. Cross, "The validity of polygraph testing: Scientific analysis and public controversy", *American Psychologist*, vol. 40, no. 3, pp. 355–366, 1985.
- [4] V. Abootalebi, M.H. Moradi, dan M.H. Khalilzadeh, "A new approach for EEG feature extraction in P300-based lie detection", *Computer Methods and Programs in Biomedicine*, vol. 94, pp. 48–57, 2009.
- [5] J. Gao, H. Tian, Y. Yang, X. Yu, C. Li, dan N. Rao, "A Novel Algorithm to Enhance P300 in Single Trials: Application to Lie Detection Using F-Score and SVM", *PLoS ONE*, vol. 9, no. 11, 2014.
- [6] J.P. Rosenfeld, M. Soskins, G. Bosh, dan A. Ryan, "Simple, effective countermeasures to P300-based tests of detection of concealed information", *Psychophysiology*, vol. 41, no. 2, 2004.
- [7] A.E. Selim, M.A. Wahed, dan Y.M. Kadam, "Machine learning methodologies in P300 speller Brain-Computer Interface systems", *26th National Radio Science Conference 2009*, pp. 1-9.
- [8] R. Oostenveld, P. Fries, E. Maris, dan J.M. Schoffelen, "FieldTrip: open source software for advanced analysis of MEG, EEG, and invasive electrophysiological data", *Computational intelligence and neuroscience*, 2010.
- [9] A.G. Reddy dan S. Narava, "Artifact Removal from EEG Signals", *International Journal of Computer Applications*, vol. 77, no. 13, pp. 17-19, 2013.
- [10] P. Comon, "Independent component analysis, a new concept?", *Signal Processing*, vol. 36, pp. 287-314, 1994.
- [11] N.P. Castellanos dan V.A. Makarov, "Recovering EEG signals: Artifact suppression with wavelet enhanced independent component analysis", *Journal of Neuroscience Methods*, vol. 158, pp. 300-312, 2006.
- [12] T.P. Jung, S. Makeig, M. Westerfield, J. Townsend,



- E. Courchesne, dan T.J. Sejnowski, "Removal of eye activity artifacts from visual event-related potentials in normal and clinical subjects", *Clinical Neurophysiology*, vol. 111, no. 10, pp. 1745-1758, 2000.
- [13] J. Altmann, *Surfing the Wavelets*, 2006. <http://www.wavelet.org/tutorial/> (diakses 24 Agustus 2015)
- [14] A. Subasi, "EEG signal classification using wavelet feature extraction and a mixture of expert model", *Expert Systems with Applications*, vol. 32, no. 4, pp. 1084-1093, 2007.
- [15] J.S.R. Jang, "ANFIS: adaptive-network-based fuzzy inference system, IEEE Transactions on Systems", *Man and Cybernetics*, vol. 23, no. 3, pp. 665-685, 1993.
- [16] S. Eswaramoorthy, N. Sivakumaran, R. Sundarajan, "Classification of intracranial electroencephalographic signals using adaptive neuro-fuzzy inference system", *Proceedings of the ESA Annual Meeting on Electrostatics 2014*.
- [17] I. Güler dan E.D. Übeyli, "Adaptive neuro-fuzzy inference system for classification of EEG signals using wavelet coefficients", *Journal of Neuroscience Methods*, vol. 148, no. 2, pp. 113-121, 2005.
- [18] H. Koivo, ANFIS (Adaptive Neuro-Fuzzy Inference System), 2000. <ftp://ftp.ucauca.edu.co/Facultades/FIET/DEIC/Materia/Control%20Inteligente/Parte%20III/clase%203%20Int/FVAnfis2.pdf> (diakses 15 Juli 2015)