

Aşırı Öğrenme Makineleri ile biyolojik sinyallerin gizli kaynaklarına ayrıştırılması

Ömer Faruk ERTUĞRUL^{*1}

¹ Batman Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, Batman

Makale Gönderme Tarihi: 30.01.2016

Makale Kabul Tarihi: 22.02.2016

Öz

Artan teknoloji, düşen maliyetler ve küçülen donanım boyutları nedeniyle işaret işleme yöntemleri birçok alanda sıklıkla kullanılmaya başlanmıştır. Algılanan bazı sinyaller tek bir kaynaktan değil de birçok kaynaktan oluşan sinyallerin karışımı olabilmektedir. Bu tip durumlarda işaret işleme teknikleriyle elde edilebilecek başarı oranı düşüktür. Aynı zamanda sistemin iç yapısının anlaşılması zordur. Bu tip durumlarda gizli kaynak ayrıştırma işlemi ile ölçülen sinyaller gizli kaynaklarına ayrıştırılabilmektedir. Bu amaçla yaygın olarak kullanılan temel kaynak ayrıştırma (PCA) ve bağımsız kaynak ayrıştırma (ICA) istatistiksel yöntemlerinde sinyallerin ayrıştırılabileceği gizli kaynak sayısı ölçülen sinyal sayısı ile sınırlıdır. Bu sebeple karmaşık sinyallerde gizli kaynaklara ulaşmak bu yöntemlerle zordur.

Bu yöntemlere alternatif olarak yapay sinir ağları (YSA) da gizli kaynak ayrıştırma amacıyla başarıyla kullanılmıştır. Bu çalışmada ise tek gizli katmanlı ileri beslemeli yapay sinir ağlarını eğitmek için kullanılan aşırı öğrenme makineleri (ELM) yöntemi klasik YSA ile gizli kaynak ayrıştırma yöntemlerinden farklı bir yaklaşım ile kullanılarak tek bir sinyal birden fazla birbirinden bağımsız gizli kaynağa ayrıştırılmıştır. Bu amaçla EEG, EMG, ECG sinyalleri ile ivmeölçer, magnetometre ve jiroskop algılayıcılarından alınan zaman sinyalleri gizli kaynaklarına ayrıştırılmıştır.

Önerilen metodun başarısını eğitim başarısını gösteren ortalama hataların karekökü (RMSE) ve gizli kaynakların bağımsızlığını gösteren kovaryans kullanılmıştır. Test sinyallerinde 10^{-4} - 64×10^{-4} aralığında RMSE ve 0.2×10^{-4} - 38.3×10^{-4} aralığında kovaryans değerleri elde edilmiştir. Elde edilen RMSE değerleri YSA'nın başarılı olarak eğitildiğini, elde edilen kovaryans değerleri ise ayrıştırılmış sinyallerin birbirinden bağımsız olduğunu göstermiştir. Ayrıca 2 adet epileptik ve 2 adet normal EEG sinyali 16 ayrı gizli kaynağa kadar ayrıştırılmıştır. Dört örnekte de elde edilen başarı oranları önerilen metodun gizli kaynak ayrıştırma başarıyla kullanılabileceğini göstermiştir.

Anahtar Kelimeler: Gizli kaynak ayrıştırma; İşaret işleme; Aşırı Öğrenme Makineleri; Yapay Sinir Ağları

*Yazışmaların yapılacağı yazar: Ömer Faruk ERTUĞRUL, omerfarukertugrul@gmail.com; Tel: (488) 217 37 19

Giriş

Artan teknolojiye paralel olarak işaret işleme teknikleri günümüzde yoğun olarak birçok farklı amaçla kullanılmaktadır. Çeşitli algılayıcılar kullanılarak ölçülen sinyaller, ölçüm yeri ve amacına göre farklı şekilde isimlendirilmekte ve farklı yöntemler ile incelenmektedir. Örneğin, elektroensefalografi (EEG), elektromiyografi (EMG) veya elektrokardiyografi (ECG) sinyalleri hasta teşhisi ve bilgisayar beyin ara yüzü gibi sistemlerde yoğun olarak kullanılmaktadır (Özerdem vd., 2003; Aydemir ve Kayıkçioğlu, 2009; Karadağ ve Özerdem, 2014; Sezgin, 2013). Genel olarak elektronik sistemlerde algılayıcılar kullanılarak söz konusu sistemin herhangi bir alt sisteminin durumu ile ilgili bilgiler alınarak işlenmekte ve buna bağlı olarak kararlar alınmaktadır. Örneğin, enerji iletim sistemlerinde yüksek akım seviyesinde iletilen anlık elektrik akım ve gerilim değerleri trafolar marifetiyle daha düşük değerlere dönüştürülmekte ve bunlar kullanılarak iletim hattında oluşan bir arıza durumunda arızalı hat iletim sisteminden hızla izole edilerek sistemin geri kalanının oluşan arızadan etkilenmemesi sağlanmaya çalışılmaktadır (Ertuğrul vd., 2013). Ancak bazı durumlarda algılayıcılar tarafından alınan bilgi birden fazla etkinin lineer toplamı şeklinde olmaktadır (Belouchrani ve Amin, 1998).

Biyolojik sinyaller genel olarak birçok etkinin birleşmesiyle oluşan karmaşık sinyallerdir (Lin vd., 2010). Örneğin, EEG sinyalleri genel olarak kafatasının dışına yerleştirilen birçok elektrot ile ölçülmektedir. Bu sebeple ölçülen EEG sinyalleri beyinin elektroda yakın olan bölgesinde oluşan tüm elektriksel aktivitenin toplamını kaydetmektedir. Ölçülen sinyalin kaynağının tam olarak bilinmemesinden dolayı sinyallerin analizi ve buna bağlı olarak hastalık teşhisi zor olmaktadır.

Bu tip durumlarda birçok farklı kaynaktan oluşan ve kaynağı bilinmeyen sinyalleri hiçbir ön bilgiye ihtiyaç duyulmadan ayrıştırılması için gizli kaynak ayrıştırma yöntemleri kullanılmaktadır. Gizli kaynak ayrıştırma

yöntemleri akustik, biyomedikal, dijital haberleşme, finansal analiz, jeofizik, görüntü işleme ve istatistik gibi alanlarda kullanılmaktadır (Kokkinakis ve Loizou, 2010; Kirei vd., 2011). Bu amaçla en yaygın olarak kullanılan istatistiksel yaklaşımlar bağımsız bileşen analizi (ICA) ve temel bileşen analizidir (PCA). Bu iki yöntemde de temel olarak sinyali birbirinden istatistiksel olarak bağımsız birden fazla sinyale ayırtmak hedeflenmektedir (Sezgin vd., 2012; Choi, 2005). Ancak bunun yapılabilmesinin en temel şartı algılayıcı sayısının ayrıştırılmak istenen gizli kaynak sayısından fazla olmasıdır. Bu yöntemlere alternatif olarak tek bir sinyalin birden fazla sinyale ayrıştırılması için gecikmeler yöntemi önerilmiştir (Takens, 1981). Bu yöntem özellikle EEG analizinde sıklıkla kullanılmaktadır (Chaovalitwongse vd., 2005; Casdagli vd., 1997; Iasemidis vd., 1988). Bu yöntemde zaman sabitinin optimal olarak atanması hayati önem taşımaktadır.

Yapay sinir ağırları (YSA) ise birçok alanda başarı ile kullanıldığı gibi bağımsız kaynak ayrıştırma amacıyla da kullanılmıştır (Karhunen vd., 1997; Kokkinakis ve Loizou, 2010; Choi, 2005; Liang vd., 1994). İleri beslemeli, geri beslemeli, radyal tabanlı ve kendinden düzenlemeli YSA gibi birçok farklı YSA türü bu amaçla kullanılmıştır (Kokkinakis ve Loizou, 2010; Meyer-Bäse vd., 2006; Tan vd., 2001). Ayrıca, Zomorodi vd. (2006) yapmış oldukları çalışmada YSA ile gizli kaynak ayrıştırmanın, PCA ve ICA'ya kıyasen daha başarılı olduğu görülmüştür.

Bu çalışmada, Huang vd. (2006) tarafından tek gizli katmanlı ileri beslemeli YSA'nın eğitiminde kullanılmak üzere önerilmiş olan aşırı öğrenme makinelerinin (ELM) gizli kaynak ayrıştırmada kullanılabileceği önerilmiş ve performansı test edilmiştir. ELM'de giriş katmanı ağırlıkları ve eşik değerleri rastgele atanmakta, çıkış katmanı ağırlıkları ise analitik olarak hesaplanmakta olduğundan geri beslemeli ile öğrenen YSA'dan ve destek vektör makineleri gibi birçok yöntemden daha hızlı eğitilebilmekte ve sonuçta daha yüksek

genelleme kabiliyetine sahip olmaktadır (Huang vd., 2006, Ertuğrul ve Kaya, 2014).

Bu çalışmada ELM'nin bu avantajları kullanılarak hızlı, başarılı ve kolay kullanılabilir yeni bir gizli kaynak ayrıştırma yöntemi önerilmiştir. Literatürdeki metotlar genelde ağırlık değişimleri temel alınarak sinyaller gizli kaynaklarına bölünmektedir (Tan vd., 2001). Ancak bu çalışmada önerilen metot literatürde önerilen YSA ile gizli kaynak ayrıştırma yöntemlerinden farklı olarak gizli katmanda bulunan her bir sinir hücresinin çıkışındaki aktivasyon fonksiyonu olarak birbirine dikey (orthogonal) olan farklı fonksiyonlar kullanılmıştır. Ayrıca önerilen yöntem ile tek bir sinyal birçok bağımsız gizli kaynağa ayrıştırılmıştır. Önerilen yöntemin başarısını değerlendirmek için biyolojik sinyallerin gizli kaynaklarına ayrıştırılması sürecinde ELM'nin eğitim sürecindeki hata oranı ve kaynaklarına ayrıştırılan sinyallerin bağımsızlığını gösteren kovaryans kullanılmıştır.


Materyal ve Yöntem

Materyal

Yapılan çalışmada Dicle Üniversitesi, Tıp Fakültesi, Nöroloji Bölümünde kaydedilmiş olan epileptik EEG, normal EEG sinyalleri ve ECG sinyalleri, ayrıca UCI tarafından paylaşılan saldırgan-normal hareketlere ait EMG sinyalleri ve MHealth veri setinde bulunan çeşitli hareketlerin yapılması sürecinde ivmeölçer, magnetometre ve jiroskop algılayıcılarınca kaydedilen sinyaller kullanılmıştır (Lichman, 2013). Kullanılan sinyallerin birer örneği Şekil 1'dedir.

Aşırı Öğrenme Makineleri (ELM)

ELM tek bir gizli katmana sahip ileri beslemeli yapay sinir ağlarını eğitmek için önerilmiş bir yöntemdir (Huang vd., 2006 ve 2011). Tek gizli katmanlı YSA'nın yapısı Şekil 2'de verilmiştir.



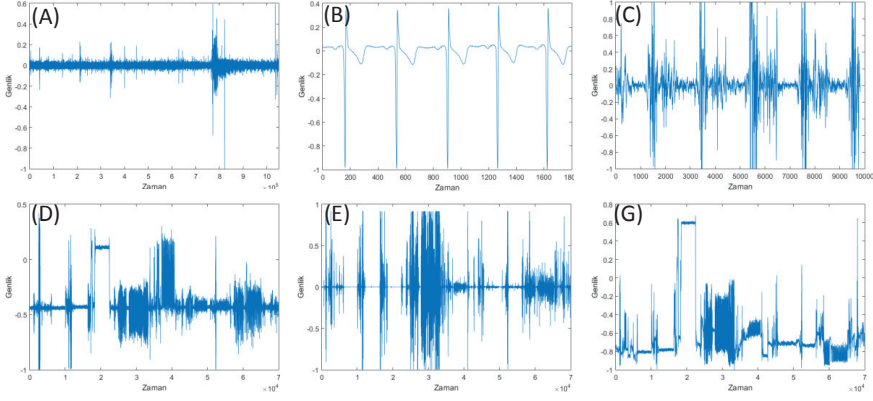
Şekil 2. Tek Gizli Katmanlı YSA (Ertuğrul vd., 2013)

Şekil 2'de gösterilen yapay sinir ağının çıkışı:

$$Y_p = \sum_{j=1}^m \beta_{j,k} g\left(\sum_{i=1}^n w_{i,j} x_i + b_j\right) \quad (1)$$

ile hesaplanmaktadır. Burada $x_1 \dots x_n$ giriş vektörlerini, $y_1 \dots y_p$ çıkış vektörlerini, $\beta_1 \dots \beta_m$ çıkış katmanı ağırlıklarını, $W_{1 \dots n, 1 \dots m}$ giriş katmanda ile gizli katman arasındaki bağlantı ağırlıklarını, $b_{1 \dots m}$ eşik değerlerini ve $g(\cdot)$ ise aktivasyon fonksiyonunu göstermektedir (Kaya, 2013).

YSA'nın başarılı bir şekilde öğrenebilmesi ağırlıklar, eşik değerleri ve transfer fonksiyonu modellenecek sistemin karakterine en uygun şekilde seçimiyle yapılmaktadır. Geri yayımlı öğrenme algoritması gibi gradyan temelli öğrenme yaklaşımlarında ağırlıklar ve eşik değerlerinin tamamı iteratif olarak en uygun değeri (eğitim hatasını en aza indirildiği yer) alınca kadar değiştirilmektedir. Bu sebeple genel olarak yavaş ve yerel minimumlar nedeniyle eğitim hata oranı yüksek değerler alabilmektedir. ELM'de ise giriş katmanı ağırlıkları ve eşik değerleri rastgele atanmakta ve çıkış ağırlık değerleri buna bağlı olarak hesaplanmaktadır (Ertuğrul ve Kaya, 2014).



Şekil 1. (A) Epileptik EEG sinyali; (B) ECG sinyali; (C) EMG sinyali; (D) İvmeölçer; (E) Magnetometre sinyali; (F) Jiroskop sinyali

n tane giriş nöronu, m tane gizli katman nöronu (eğitim kümesindeki örnek sayısına eşit veya daha az olmalıdır) bulunan bir YSA için giriş katmanını ağırlıkları ($W_{i,j}$) ve eşik değerleri (b_j) rastgele belirlendiğinde, atanan türevlenemeyen veya kesikli aktivasyon fonksiyonları da dahil olmak üzere herhangi bir transfer fonksiyonu ($g(\cdot)$) için çıkış katmanının girişi:

$$H = \begin{bmatrix} g(w_{1,1}x_1 + b_1) & \cdots & g(w_{1,m}x_m + b_m) \\ \vdots & \ddots & \vdots \\ g(w_{n,1}x_1 + b_1) & \cdots & g(w_{n,m}x_m + b_m) \end{bmatrix} \quad (2)$$

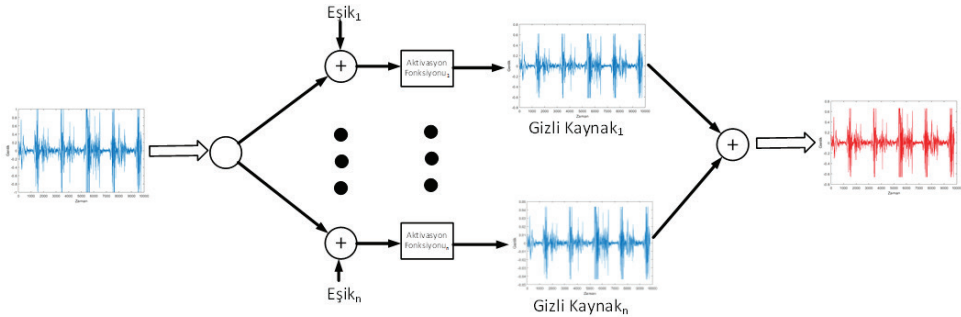
şeklinde. Bu durumda çıkış denklemi:

$$y = H\beta \quad (3)$$

olur. Genel olarak eğitim kümesindeki gözlem sayısı ve özellik sayısının birbirine eşit olma olasılığının düşüklüğü nedeniyle H matrisinin ters matrisi geliştirilmiş ters Moore-Penrose matrisi ile hesaplanmaktadır ve çıkış ağırlıkları (β) (Huang vd., 2006 ve 2011):

$$\hat{\beta} = H^+y \quad (4)$$

şeklinde bulunur. Burada H^+ , H matrisinin geliştirilmiş ters Moore-Penrose matrisi, $\hat{\beta}$ ise çıkış katmanındaki ağırlıklardır.



Şekil 3. Önerilen yöntem

Önerilen Yöntem

Önerilen yöntem Şekil 3'te gösterilmiştir. Alınan bir sinyal ayrıştırılmak istenen kaynak sayısı kadar gizli katmanında nöron bulunan ileri beslemeli YSA'ya giriş olarak verilmektedir. Çıkış olarak aynı sinyal kullanılır. Eğitim sürecinde girişte uygulanan sinyali aynı şekilde çıkışta elde edebilecek şekilde çıkış katmanı ağırlıkları optimize edilir.

Çıkış katmanının girişlerinin her biri farklı bir gizli kaynak sinyalini vermektedir. Çıkışta elde edilen sinyal ise Belouchrani ve Amin'in (1998) belirttikleri gibi gizli etkilerin lineer toplamıdır.

Başarı Ölçütü

Yapılan çalışmada ELM ile bir YSA'nın aynı girişe karşılık aynı çıkışı üretebilmesi için eğitilmektedir. Eğitim sürecinin başarı ortalama hataların karekökü (RMSE) ile aşağıdaki şekilde hesaplanmıştır.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (f_i - y_i)^2} \quad (5)$$

RMSE hata parametresine ilaveten, gizli kaynakların ayrıştırılması için iki rastgele değişkenin beraber değişimlerini gösteren istatistiksel kovaryans değişkeni kullanılmıştır. X ve Y sinyallerinin kovaryansı ($cov(X, Y)$) aşağıdaki şekilde hesaplanır (Hyvärinen ve Oja, 2000).

$$cov(X, Y) = E[XY] - E[X]E[Y] \quad (6)$$

Burada E beklenen değeri göstermektedir. Beklenen değer birçok farklı anlama gelmektedir, bunlardan biri de istatistikte ortalama değerdir ve

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \quad (7)$$

şeklinde hesaplanır. Eğer X ve Y birbirinden bağımsız sinyaller olarak alınırsa:

$$E[XY] = E[X]E[Y] \quad (8)$$

olur. Sonuç olarak Eğer X ve Y birbirinden bağımsız sinyaller ise o zaman onların kovaryansları sıfır olur (Hyvärinen ve Oja, 2000). Aynı şekilde kovaryans değerinin sıfıra yakınlığı sinyallerin bağımsızlığını göstermektedir.

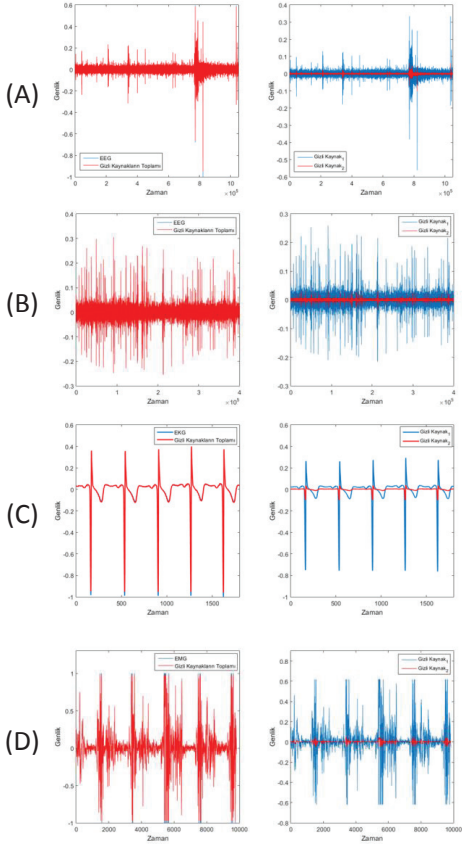
Uygulama ve Başarımlar

Önerilen metot ile biyolojik sinyaller dikey (sinüs ve kosinüs) aktivasyon fonksiyonları kullanılarak iki ayrı gizli kaynağa ayrıştırılmıştır ve bu kaynaklar Şekil 4 ve 5'te gösterilmiştir. İlk grafikte orijinal sinyal ve ayrıştırılan gizli kaynakların toplamı, ikinci grafikte ise her iki gizli kaynak zamansal düzlemde gösterilmiştir. Şekil 4 ve 5'te bulunan gizli kaynakların toplamı ve orijinal sinyaller incelendiğinde önerilen YSA'nın giriş ve çıkış arasındaki ilişkiyi başarıyla öğrendiği görülmüştür. Ayrıca ayrıştırılmış sinyaller incelendiğinde sinyallerin birbirinden farklı olduğu görülmüştür. Elde edilen eğitim başarısı ve gizli kaynakların arasındaki kovaryans değerleri Tablo 1'de verilmiştir.

Tablo 1. Başarı Oranları (Dikey Aktivasyon Fonksiyonu)

SİYAL	EĞİTİM BAŞARISI	KOVARYANS
EPILEPTİK EEG	0,00010	0,00002
NORMAL EEG	0,00072	0,00143
EKG	0,00490	0,00160
EMG	0,00640	0,00173
İVMEÖLÇER	0,00165	0,00115
MAGNETOMETRE	0,00040	0,00044
JİROSKOP	0,00635	0,00383

Tablo 1'de gösterilen RMSE değerleri eğitimin başarılı olduğu ve sinyallerin başarıyla ayrıştırıldığını ifade etmektedir. Ayrıca kovaryans değeri ise ayrıştırılmış sinyallerin tamamen bağımsızlığa yakın olduğunu (neredeyse bağımsız) göstermektedir.



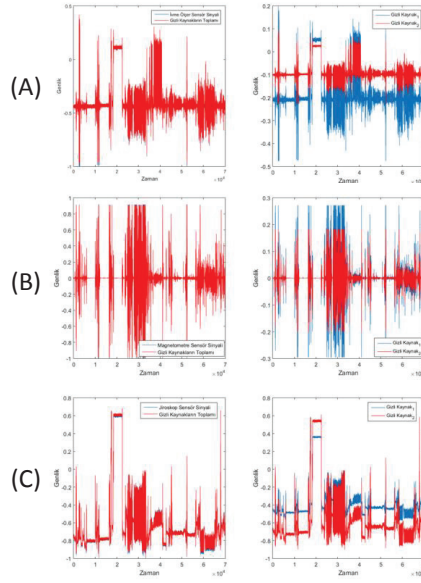
Şekil 4. (A) Epileptik EEG Sinyali; (B) Normal EEG Sinyali; (C) ECG Sinyali; (D) EMG Sinyali

Tablo 2’de ise birbirine dikey farklı aktivasyon fonksiyonları yerine sigmoid aktivasyon fonksiyonu kullanıldığında elde edilen başarı değerleri gösterilmiştir.

Tablo 2. Başarı Oranları (Normal Aktivasyon Fonksiyon)

SİNYAL	EĞİTİM BAŞARISI	KOVARYANS
EPİLEPTİK EEG	0,00014	0,00015
NORMAL EEG	0,00093	0,00163
EKG	0,00516	0,00216
EMG	0,0472	0,0177
İVMEÖLÇER	0,01215	0,00555
MAGNETOMETRE	0,00113	0,00243
JİROSKOP	0,10831	0,00819

Tablo 4 ve 5 incelendiğinde gizli katmanın çıkışlarında birbirinden farklı ve dikey aktivasyon fonksiyonları kullanıldığında aynı aktivasyon fonksiyonu kullanılmasına kıyasla daha yüksek başarı ve daha düşük kovaryans değerleri elde edilmiştir.



Şekil 5. (A) İvme Ölçer Sensör Sinyali; (B) Magnetometre; (C) Jiroskop

Sonuçlar ve Tartışma

Bu çalışmada EEG, ECG, EMG, ve algılayıcılardan alınan sinyallerin gizli kaynaklarına ayrıştırılması için ELM temelli bir gizli kaynak ayrıştırma yöntemi önerilmiştir. Önerilen yöntemin başarısını test etmek için eğitim sırasında elde edilen RMSE değeri ve ayrıştırılmış sinyallerin bağımsızlığını gösteren kovaryans kullanılmıştır. Önerilen metodun başarısını artırmak için gizli katmanın çıkışında bulunan aktivasyon fonksiyonları genelde kullanılan aksine birbirinden farklı ve dikey fonksiyonlar atanmıştır. Dikey fonksiyonlar kullanıldığında elde edilen başarı oranları (Tablo 1) ile dikey olmayan tek bir fonksiyon kullanıldığında elde edilen başarı oranları (Tablo 2) karşılaştırıldığında dikey aktivasyon fonksiyonları kullanımında: (1) eğitimin daha

başarılı olduğu ve (2) ayrıştırılan sinyallerin birbirinden daha fazla bağımsız olduğu görülmüştür.

Çalışma sonuçları biyolojik sinyallerin YSA kullanılarak gizli kaynaklarına ayrıştırılabileceğini gösteren Lin vd. (2010) sonuçlarıyla örtüşmektedir. Elde edilen RMSE değerleri 10^{-4} - 64×10^{-4} mertebelerindedir. Lin vd. (2010) yaptıkları YSA ile gizli kaynaklarına ayrıştırma çalışmasında eğitim sürecinin hata oranını 10^{-2} (MSE) mertebelerinde bulmuştur. Bu sebeple önerilen metotta eğitim sürecinin başarılı olduğu görülmüştür.

Bulunan düşük kovaryans değerleri ayrıştırılan sinyallerin istatistiksel olarak bağımsız olduklarını göstermektedir. Bu değerlerin elde edilmesinde en büyük nedenin birbirinden farklı ve dikey aktivasyon fonksiyonları kullanılması olduğu görülmüştür. Ayrıca gizli kaynak sinyallerinin genliklerinin birbirinden farklı oldukları görülmüştür. Liang vd. (1994) yaptıkları ayrıştırma çalışmasında sinyaller arasında 100:1 oranında genliksel fark olduğunu raporlamışlardır. Bu çalışmada da daha düşük

oranlarda olsa da ayrıştırılmış sinyaller arasında genlik farkları görülmüştür.

Ayrıca farklı boyutlarda alınmış bir epileptik EEG sinyallerinin farklı sayıda gizli kaynağa ayrıştırma işlem süreci Tablo 3'te verilmiştir.

Tablo 3. İşlem Süresi (sn)

SİNYAL BOYUTU	GİZLİ KAYNAK SAYISI		
	2	5	10
1x100	0,2626	0,2695	0,2412
1x1000	0,2660	0,2418	0,2428
1x5000	0,2668	0,2605	0,2529
1x20000	0,2735	0,2571	0,2831
1x100000	0,2906	0,3176	0,4253
1x500000	0,3234	0,6801	1,2884
1x1000000	0,3740	1,1145	2,3337

Tablo 3'teki işlem süreleri göz önüne alındığında önerilen metodun çok büyük boyutlarda bile birkaç saniye içerisinde sinyali ayrıştırılabildiği görülmüştür. İlaveten iki adet epileptik ve iki adet normal EEG sinyallerinin farklı sayıda gizli kaynaklarına ayrıştırılmaları durumunda elde edilen RMSE ve kovaryans değerleri Tablo 4'te verilmiştir.

Tablo 4. Farklı Sayıda Gizli Kaynağa Ayrıştırıldığında Elde Edilen Başarı Oranları

GİZLİ KAYNAK SAYISI	EPİLEPTİK EEG SİNYALİ				NORMAL EEG			
	1. ÖRNEK SİNYAL		2. ÖRNEK SİNYAL		1. ÖRNEK SİNYAL		2. ÖRNEK SİNYAL	
	KOVARYANS	RMSE	KOVARYANS	RMSE	KOVARYANS	RMSE	KOVARYANS	RMSE
1	0,0001	0,0016	0,0001	0,0025	0,0001	0,0062	0,0010	0,0064
2	0,0001	0,0150	0,0002	0,0080	0,0001	0,0228	0,0006	0,0286
3	0,0001	0,0169	0,0001	0,0108	0,0006	0,0198	0,0004	0,0309
4	0,0004	0,0167	0,0001	0,0103	0,0009	0,0179	0,0005	0,0273
5	0,0003	0,0194	0,0003	0,0102	0,0010	0,0238	0,0004	0,0313
6	0,0013	0,0284	0,0001	0,0074	0,0019	0,0288	0,0008	0,0226
7	0,0008	0,0312	0,0002	0,0092	0,0021	0,0266	0,0003	0,0167
8	0,0002	0,0275	0,0001	0,0093	0,0017	0,0275	0,0001	0,0163
9	0,0009	0,0298	0,0002	0,0088	0,0021	0,0258	0,0002	0,0158
10	0,0008	0,0319	0,0002	0,0136	0,0034	0,0287	0,0005	0,0158
11	0,0009	0,0317	0,0005	0,0115	0,0058	0,0288	0,0010	0,0153
12	0,0007	0,0289	0,0003	0,0130	0,0044	0,0289	0,0005	0,0158
13	0,0007	0,0297	0,0001	0,0137	0,0035	0,0296	0,0014	0,0151
14	0,0012	0,0274	0,0003	0,0130	0,0054	0,0299	0,0012	0,0159
15	0,0020	0,0258	0,0002	0,0113	0,0048	0,0308	0,0012	0,0156
16	0,0018	0,0272	0,0002	0,0124	0,0052	0,0317	0,0009	0,0153

Tablo 4'te gösterilen sonuçlar önerilen metodun gizli kaynaklarına ayırtırmada başarılı olduğunu göstermektedir. Ayrıca ayırtırılmak istenen kaynak sayısı ile elde edilen eğitim hata oranı veya gizli kaynakların bağımsızlığı arasında düzenli bir ilişkinin olmadığı gözlemlenmiştir.

Kaynaklar

- Aydemir, Ö., Kayıkcıoğlu, T., (2009). "EEG Tabanlı Beyin Bilgisayar Arayüzleri", Akademik Bilişim Konferansı, 7-13.
- Belouchrani, A., Amin, M. G., (1998). "Blind source separation based on time-frequency signal representations", IEEE Transactions on Signal Processing, 46,11, 2888-2897.
- Casdagli, M. C., Iasemidis, L. D., Savit, R. S., Gilmore, R. L., Roper, S. N., Sackellares, J. C., (1997). "Non-linearity in invasive EEG recordings from patients with temporal lobe epilepsy", Electroencephalography and clinical Neurophysiology, 102, 2, 98-105.
- Chaovalitwongse, W., Iasemidis, L. D., Pardalos, P. M., Carney, P. R., Shiau, D. S., Sackellares, J. C., (2005). "Performance of a seizure warning algorithm based on the dynamics of intracranial EEG", Epilepsy research, 64, 3, 93-113.
- Choi S., (2005). "Blind source separation and independent component analysis: A review", Neural Information Processing-Letters and Reviews, 6, 1, 1-57.
- Ertuğrul, Ö. F., Kaya Y., (2014). "A detailed analysis on extreme learning machine and novel approaches based on ELM", American Journal of Computer Science and Engineering, 1,5,43-50.
- Ertuğrul, Ö. F., Tağluk, M. E., Kaya Y., (2013). "Enerji İletim Hatlarında Oluşan Arızaların Aşırı Öğrenme Makinesi ile Tespiti", 21. Sinyal İşleme ve İletişim Uygulamaları Kurultayı, SIU2013.
- Huang, G. B., Zhu Q. Y., Siew C. K., (2006). "Extreme learning machine: Theory and applications", Neurocomputing, 70, 489-501.
- Huang, G. B., Wang, D. H., Lan, Y., (2011). "Extreme learning machines: a survey", Int. J. Mach. Learn. & Cyber., 2, 107-122.
- Hyvärinen, A., Oja, E., (2000). "Independent component analysis: algorithms and applications", Neural networks, 13, 4, 411-430.
- Iasemidis, L. D., Zaveri, H. P., Sackellares, J. C., Williams, W. J., (1988). "Phase space analysis of EEG in temporal lobe epilepsy", IEEE 10th Annual International Conference on Engineering in Medicine and Biology, 1201-1203.
- Karadağ, K., Özerdem M. S., (2014). "Dalgacık Dönüşümü Kullanılarak Fare EEG İşaretlerinde Epileptik Nöbet Tespiti", Tıbbi Tanı ve Tedavi Sistemlerinde Sinyal İşleme Uyg. 78-81.
- Karhunen, J., Oja, E., Wang, L., Vigario, R., Joutsensalo, J., (1997). "A class of neural networks for independent component analysis", IEEE Transactions on Neural Networks, 8, 3, 486-504.
- Kaya, Y., (2013). "A new intelligent classifier for breast cancer diagnosis based on rough set and extreme learning machine: RS+ELM", Turkish Journal of Electrical Engineering and Computer Sciences, 21, 2079-2091.
- Kirei, B. S., Topa, M. D., Muresan, I., Homana, I., Toma, N., (2011). "Blind Source Separation for Convolutional Mixtures with Neural Networks", Advances in Electrical and Computer Engineering, 11, 1, 63-68.
- Kokkinakis, K., Loizou, P. C., (2010). "Advances in Modern Blind Signal Separation Algorithms: Theory and Applications", Synthesis Lectures on Algorithms and Software in Eng., 2, 1, 2-24.
- Lichman, M. (2013). "UCI Machine Learning Repository", [http://archive.ics.uci.edu/ml]. Irvine, CA: University of California, School of Information and Computer Science.
- Lin, Y. D., Hsu, C. Y., Chen, H. Y., Tseng, K. K., (2010). "An efficient ICA approach based on neural network framework for biomedical applications", IEEE International Joint Conference on Neural Networks (IJCNN), 1-8.
- Ling, X. T., Huang, Y. F., Liu, R. W., (1994). "A neural network for blind signal separation", IEEE International Symposium on Circuits and Systems, ISCAS'94, 6, 69-72.
- Meyer-Bäse, A., Gruber, P., Theis, F., Foo, S., (2006). "Blind source separation based on self-organizing neural network", Engineering Applications of Artificial Intelligence, 19, 3, 305-311.
- Sezgin, N., Tağluk, M. E., Tekin, R., (2012). "Separation of EEG signals by using Independent Component Analysis", IEEE 20th Signal Processing and Communications Applications Conference, 1-4.
- Sezgin N., "Nonlinear Analysis of Electrocardiography Signals for Atrial Fibrillation", Scientific World Journal, 1-4, 2013.

- Özerdem, M. S., Koçyiğit, Y., Korürek, M., (2003). "Dalgacık Dönüşümü ve Yapay Sinir Ağları ile Elektromiyografik İşaretlerin Sınıflandırılması", 11. Sinyal İşleme ve İletişim Uygulamaları.
- Takens, F., (1981). "Detecting strange attractors in turbulence", Dynamical Systems and Turbulence, Lecture Notes in Mathematics. Springer-Verlag, Heidelberg, 366-381.
- Tan, Y., Wang, J., Zurada, J. M., (2001). "Nonlinear blind source separation using a radial basis function network", IEEE Transactions on Neural Networks, 12, 1, 124-134.
- Zomorodi, A. R., Nasernejhad, B., Kabudian, J., (2006). "Comparison of MLP NN Approach with PCA and ICA for Extraction of Hidden Regulatory Signals in Biological Networks", Iranian Journal Of Chemistry and Chemical Engineering (IJCCE), 25, 4, 1-7.
- Zomorodi, A., Nasernejhad, B., Dehkordi, MR., Kabudian, J., (2005). "A Comparison of PCA, ICA and Neural Network-based Approaches for Determination of Regulatory Signals in Biological Systems", IKT.

Blind signal separation in biological by Extreme Learning Machines

Extended abstract

Improvements in the technology cause not only decrease in the sensor costs but also, reduce the dimensions of the sensors. Based on these facts the importance of signal processing methods increases day by day. But, in most applications sensors pick up a collection or mixture of signals from many sources instead of only one sensor. In this case, it is hard to understand or manipulate the system. For example, recorded EEG signals are mixtures of action potentials of many neurons, therefore, the reasons or mechanisms behind epilepsy are still since unknown.

For such situations, blind signal separation methods have been employed. Generally, used blind signal separation methods are principal component analysis (PCA) and independent component analysis (ICA) methods. Although many successful results of PCA and ICA have been reported in the literature, they suffer from a major drawback; the number of sources that will be separated must be equal or less than the number of sensors. Therefore, it is hard to obtain the true sources of complex signals by these methods. As an alternative, the method of delay was proposed to separate a signal into two independent sources, but its performance is highly dependent on the delay value.

Addition to these methods, artificial neural network (ANN) was also employed for the purpose of blind signal separation. By ANN, better blind signal separation results with compared to PCA and ICA were reported in the literature. In this study, extreme learning machine, which is a novel learning scheme of single hidden layer feed-forward artificial neural network, was employed. In ELM, the weights and biases in the hidden layer are assigned arbitrary and the weights in the output layer are calculated analytically. Therefore, ELM showed faster training stage and higher generalization capability with compare to back-propagation trained ANN.

The proposed approach has three main contributions, which are: (1) proposed approach can be employed to separate a signal into a desired number of sources without the limitation of PCA and ICA, which is the number of sources that the signals can be separated, must be equal to or less than the observations, (2) unlike the classical ANN

approaches, in the proposed approach, an orthogonal transfer function was used in the output of each neuron in the hidden layer, and (3) the proposed approach is extremely fast because of the training scheme of ELM.

To evaluate and validate the proposed approach, biological signals, which are the EEG, ECG, EMG, accelerometer, gyroscope, and magnetometer signals, were utilized. Achieved RMSE in the training stage were in the range of 10^{-4} - 64×10^{-4} and the duration of training for different lengths of data were in the range of 0.37-2.33 sec, for separating a signal into 2 and 10 sources, respectively, while the length of the dataset is 10^6 . Additionally, obtained covariance of the separated signals were in the range of 0.2×10^{-4} - 38.3×10^{-4} .

Obtained RMSE values and fast training stage showed that the proposed approach has high accuracy in the separation of a signal and also it has an extremely fast learning stage. These advantages are because of the training scheme of ELM. Moreover, obtained covariance values showed that the separated signals are highly independent. In order to investigate the reason of obtained low covariance, a traditional transfer function was employed and not only higher covariance but also higher RMSEs were obtained. These results showed that using orthogonal transfer functions (such as sine and cosine, Bessel functions, etc.) after each neuron in the hidden layer increases the dependency of the separated signals. Furthermore, two normal EEG and two epileptic EEG signals were separated into 1-16 independent sources. Achieved results showed that there is not any relation between the numbers of separated sources with obtained the independency of sources of sources and also training accuracy.

As a summary, in this study a novel approach, which is based on ELM, was proposed in order to separate a signal into a desired number of independent sources. Achieved results showed that the proposed approach is fast and can successfully separate a signal into independent sources.

Keywords: Blind signal separation, Signal processing; Extreme Learning Machine, Artificial Neural Network