

Linear Behaviour Modelling of SBB5089Z Power Amplifier Module with Data Mining

Bilge Senel (Corresponding author)
Suleyman Demirel University, Faculty of Engineering
Electronics and Communication Engineering, Isparta, Turkey,
E-mail: bilgeturkel@sdu.edu.tr

Fatih Ahmet Senel
Suleyman Demirel University, Faculty of Engineering
Computer Engineering, Isparta, Turkey,
E-mail: fatihsenel@sdu.edu.tr

Mesud Kahrıman
Suleyman Demirel University, Faculty of Engineering
Electronics and Communication Engineering, Isparta, Turkey,
E-mail: mesudkahrıman@sdu.edu.tr

Abstract

In this study, firstly s-parameters of SBB5089Z Power Amplifier (PA) module, which could be used for the WiMAX systems at 3.5GHz and 5.8GHz have been measured according to changing DC conditions [$V_{DC}=0V:0.075V:5V$] at 3.4GHz-3.6GHz & 5.7GHz-5.9GHz frequencies. Data obtained from measurement results have been modelled separately with Artificial Neural Network (ANN), Sequential Minimal Optimization Regression (SMOReg), k-Nearest Neighbour (k-NN), K-Star (KS) algorithms. The successes of the models have been compared according to the Coefficient of determination (R^2), Root Mean Squared Error (RMSE), and Mean Absolute Error (MAE). According to obtained results it has been shown that k-NN, ANN and K-star algorithms could be successfully used in modelling linear performance parameters S_{11} , S_{12} , S_{21} , S_{22} of SB1150Z PA module.

Keywords: SBB5089Z, WiMax, data mining, modelling, s-parameters.

Veri Madenciliği ile SBB5089Z Güç Yükselteç Modülünün Doğrusal Davranış Modellemesi

Özet

Bu çalışmada, öncelikle WiMAX sistemleri için 3.5GHz ve 5.8GHz frekanslarında kullanılabilecek olan SBB5089Z Güç Yükselteci (GY) modülünün 3.4GHz-3.6GHz&5.7GHz-5.9GHz frekans aralıklarında, değişen DC koşullara [$V_{DC}=0V:0.075V:5V$] göre s-parametreleri ölçülmüştür. Ölçüm sonuçlarından elde edilen veriler Yapay Sinir Ağları (YSA), Sıralı Minimum Optimizasyon Regresyonu (SMOReg), k-En Yakın Komşuluk Algoritması (k-EYK), K-Star (KS) algoritmaları ile ayrı ayrı modellenmiştir. Modellerin başarıları Determinasyon Katsayısı (R^2), Ortalama Karesel Hatanın Karekökü (OKHK) ve Ortalama Mutlak Hata (OMH) modelleme başarı ölçütlerine göre karşılaştırılmıştır. Çalışmada elde edilen sonuçlara göre k-EYK, YSA ve K-Star algoritmalarının SBB5089Z GY modülü doğrusal performans parametrelerini (S_{11} , S_{12} , S_{21} , S_{22}) modellemede başarılı bir şekilde kullanılabileceği gösterilmiştir.

Anahtar Kelimeler: SBB5089Z, WiMax, veri madenciliği, modelleme, s-parametreleri.

1. Giriş

Haberleşme sistemleri verici birimlerinde kullanılan mikrodalga güç yükselteçleri makul bir kazanç değerinde yeterli çıkış gücü sağlaması beklenen kritik ve önemli elemanlardır. RF güç yükselteçleri için yükselteç performansı hakkında bilgi veren çok sayıda parametre bulunmaktadır (Saad 2006). Bu parametreler yükselteç doğrusal olmayan davranışı hakkında bilgi veren performans parametreleri ve yükselteç doğrusal davranışı hakkında bilgi veren performans parametreleri olarak ikiye ayrılır. Yükselteç giriş ve çıkış yansımaları hakkında bilgi veren S_{11} ve S_{22} , kazancı hakkında bilgi veren S_{21} , yükselteç çıkış-giriş portları arasında meydana gelen geri iletim hakkında bilgi veren S_{12} parametreleri yükselteç doğrusal performans parametreleridir (s-parametreleri) (David M. Pozar 2012). Bu çalışmada güç yükselteci doğrusal çalışması hakkında bilgi veren s-parametreleri (S_{11} , S_{21} , S_{22} , S_{12}) 3.4GHz-3.6GHz&5.7GHz-5.9GHz frekans aralıkları için değişen DC koşullara göre farklı veri madenciliği metotları kullanılarak modellenmiştir. Çalışmada 3.5GHz&5.8GHz WiMax frekanslarında çalışan SBB5089Z Güç Yükselteci (GY) modülünün ölçülmüş s-parametreleri (S_{11} , S_{21} , S_{22} , S_{12}) Yapay Sinir Ağları (YSA), Sıralı Minimum Optimizasyon Regresyonu (SMOReg), k-En Yakın Komşu Algoritması (k-EYK) ve K-Star Algoritması (KS) ile ayrı ayrı modellenmiş, modelleme başarı ölçütleri determinasyon katsayısı (R^2), Ortalama Karesel Hatanın Karekökü (OKHK), ve Ortalama Mutlak Hata (OMH) değerleri ile karşılaştırılmıştır. Literatürde GY'leri davranışsal modellemesinde kullanılan farklı veri madenciliği yöntemleri mevcuttur. Aynı zamanda literatür incelendiğinde çalışmalarda GY analizinde farklı performans parametrelerinin modellendiği gözlenmiştir. Hayati vd. yaptıkları çalışmalarında F-sınıfı bir GY için YSA modeli oluşturmuşlardır. İleri beslemeli olarak tasarladıkları YSA ile GY eklenmiş güç verimliliği ve çıkış gücünü modellemişlerdir (Hayati ve ark 2014). Cárdenas-Valdez vd., çalışmalarında GY'lerin dönüşüm eğrileri için nonlineerlik dereceleri ve hafıza etkileri modellemesi yapabilen bir benzetim aracı tasarlamışlardır. Önerilen araç hafıza polinomsal modelinin özel bir durumu olan Volterra serilerini ve bir öğrenme tekniği olarak da YSA'yı içermektedir. Geliştirilen sistem AM-AM ve AM-PM bozulma eğrileri ölçümlerinden elde edilen veriler ile davranış tahmini yapmakta ve analiz etmektedir (Juarez-Cazares ve ark 2016)(Ricardo Cárdenas-Valdez ve ark 2015). Literatürde farklı modelleme yöntemleri kullanılarak RF GY'lerde AM-AM ve AM-PM dönüşümleri modellenmiş çalışmalara rastlamak mümkündür (Yuan ve Feng 2013)(Renteria-Cedano ve ark 2014)(Fisher ve Al-Sarawi 2016)(Nunez-Perez ve ark 2016). Eklenmiş güç verimliliği, çıkış gücü, AM-AM dönüşümleri dışında, (Yuan ve Feng 2013) yaptıkları çalışmalarında çok katmanlı YSA modeli kullanarak IP_3 çıkış değerini tahmin etmişlerdir. Ayrıca (Senel ve ark 2016) çalışmalarında farklı modelleme metotları kullanarak eklenmiş güç verimliliği (%), IIP_3 , OIP_3 ve THD gibi performans parametreleri tahmini yapmışlardır. GY performans parametreleri modellemesi haricinde (Long ve ark 2016)(Ko ve ark 2014) çalışmalarında YSA kullanılarak GY'lerde kullanılan transistör büyük sinyal modellemeleri yapmışlardır. Literatür incelendiğinde GY'ler için farklı modelleme metotları kullanarak çok geniş skalada farklı performans parametrelerinin modellendiği görülmüştür. Ayrıca literatürde GY davranışsal modellemesinde farklı veri madenciliği yöntemlerinin kullanıldığı ve genellikle AM-AM, AM-PM bozulması gibi doğrusal olmayan performans parametrelerinin modellendiği görülmüştür. Bu çalışmada literatürdeki diğer çalışmalardan farklı olarak GY doğrusal performansı hakkında bilgi veren s-parametreleri YSA, SMOReg, k-EYK, KS algoritmaları ile ayrı ayrı modellenmiş ve sonuçlar karşılaştırılmıştır. Çalışmada öncelikle 3.4GHz-3.6GHz&5.7GHz-5.9GHz frekans aralıkları için farklı DC besleme koşullarında [$V_{DC}=0V:0.075V:5V$] SBB5089Z GY modülü s-parametreleri ölçülmüştür. Modellemeler elde edilen bu ölçüm sonuçlarına göre yapılmıştır.

Ayrıca yapılan çalışmanın tekrar edilebilir olduğunu göstermek amacıyla 100MHz-5GHz frekans aralığında çalışan SiGe HBT MMIC SGA-4186(Z) RF GY modülünün s-parametreleri (S_{11} , S_{12} , S_{21} , S_{22}), [$V_{DC}=0V:0.075V:3.2V$] DC koşulları için 3.5GHz-5GHz frekans aralığında YSA, SMOReg, k-EYK, KS algoritmaları ile ayrı ayrı modellenmiş ve başarılı sonuçlar elde edilmiştir.

2. Çalışmada Kullanılan Modeller

Çalışmada *frekans* ve *gerilim* program girdilerine karşılık program çıktısı olarak SBB5089Z GY modülünün her bir *s-parametresi* (S_{11} , S_{21} , S_{22} , S_{12})'nin WEKA 3.8 programı ile tahmin modelleri oluşturulmuştur. Tüm modeller eğitim aşamasında "Çapraz Doğrulama (Cross Validation)" tekniği ile eğitilmişlerdir. Kullanılan modellerin başarı ölçütleri R^2 (Denklem 1), OKHK (Denklem 2) ve OMH (Denklem 3) değerleri ile karşılaştırılmıştır.

$$R^2 = 1 - \frac{\sum_{i=1}^N (A_i - P_i)^2}{\sum_{i=1}^N (A_i - A_{ort})^2} \quad (1)$$

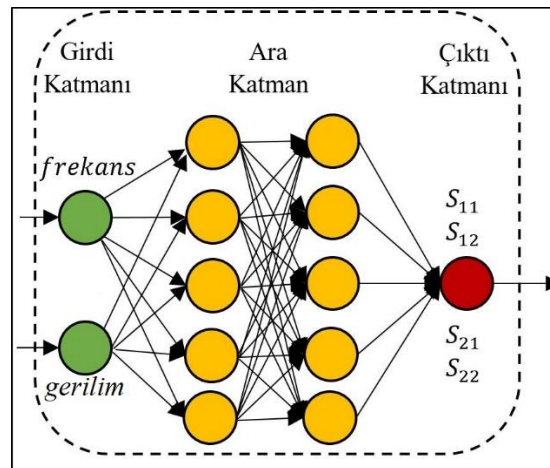
$$OKHK = \sqrt{\frac{\sum_{i=1}^N (P_i - A_i)^2}{N}} \quad (2)$$

$$OMH = \frac{\sum_{i=1}^N |P_i - A_i|}{N} \quad (3)$$

Burada N toplam örnek sayısını, A gözlemlenen gerçek değeri, P tahmin edilen değeri, A_{ort} ise gerçek değerlerin ortalamasını ifade etmektedir. Kullanılan modeller aşağıda anlatılmıştır.

2.1 Yapay Sinir Ağları

YSA, insan beyin hücrelerinde bulunan nöronların öğrenme mekanizmasından esinlenilerek geliştirilmiştir. Girdi katmanı, ara (gizli) katman ve çıktı katmanlarından oluşmaktadır. Girdi katmanında problemin girdi sayısı kadar nöron, ara katmanda kullanıcının belirlediği kadar katman ve nöronlar, çıktı katmanında ise problemin çıktı sayısı kadar nöron bulunmaktadır. Bu çalışmada modellenen problem iki adet girdiye ve bir adet çıktıya sahiptir. Yapılan modelleme her birinde beş adet nöronun bulunduğu iki adet ara katmana sahiptir (Şekil 1).



Şekil 1. Kullanılan YSA Modeli

2.2 Sıralı Minimum Optimizasyon Regresyonu

Destek Vektör Makineleri (DVM), sınıflandırma ve regresyon için geliştirilmiş danışmanlı bir makine öğrenme algoritmasıdır. DVM genel olarak sınıflandırma için kullanılmaktadır. DVM iki farklı sınıfı birbirinden ayıran hiper düzlemi bulmayı amaçlayan bir sınıflandırma yöntemidir. DVM eğitimi için Sıralı Minimum Optimizasyon (SMO) algoritması geliştirilmiştir (Platt 1998). Eğitilen DVM büyük miktarda Karesel Programlama (KP) hesaplamaları gerektirir. SMO, KP'ları küçük problemlere dönüştürerek bir iç döngüde çözmeyi amaçlar. SMO genel olarak iç ve dış döngü olmak üzere iki adet döngüden oluşur. Dış döngüde en iyi verilerin seçimi yapılırken, iç döngüde de seçilen bu verilere göre iki adet Lagrange çarpanı hesaplanır. Tüm örnekler istenilen düzeye gelinceye kadar iç ve dış döngüler çalıştırılır (Çakır ve ark 2009). SMO sınıflandırma problemlerinin haricinde regresyon işlemleri içinde kullanılabilir. Regresyon problemi çözümü için WEKA programında bulunan SMOReg algoritması kullanılmıştır. İki adet giriş (*frekans*, *gerilim*) kullanılarak bir adet çıkış s-parametresi (S_{11} , S_{21} , S_{22} , S_{12}) dB değerlerinin tahmin edilmesi amaçlanmıştır. Denklem 4'de verilen tahmin modelinin katsayıları SMOReg ile optimize edilmiştir.

$$S_{dB} = w_1 * frekans + w_2 * gerilim + b \quad (4)$$

Burada S_{dB} , dB olarak her bir s-parametresini (S_{11} , S_{21} , S_{22} , S_{12}), *frekans* ve *gerilim* algoritma giriş değerlerini, w_1 , w_2 ve b ise SMOReg yönteminin optimize ettiği katsayı ve sabiti ifade etmektedir.

2.3 k-En Yakın Komşu Algoritması

Bu çalışmada kullanılan bir diğer modelleme ise k-EYK algoritmasıdır. Bu algoritma, bir örneğin k adet seçilen eğitim uzayındaki sınıfları belli olan noktalara olan uzaklıklarına göre sınıflandırma işlemi yapmaktadır (Kucuk ve ark 2013). Uzaklık hesabı yapılırken minkowski, öklid, manhattan gibi ölçütler kullanılabilir. Bu çalışmada öklid uzaklık ölçüsü kullanılmıştır. k sayısı en iyi üç olarak seçilmiştir.

2.4 K-star Algoritması

KS algoritması, entropik uzaklığa göre örnekleri sınıflandırmaktadır (Ade ve Deshmukh 2014). Her örneğin sınıflara olan benzerlikleri ölçülerek sınıfına karar verilmektedir. Entropi rasgele değişkenlerle ilgili olan belirsizlik olasılığını ifade eder. Entropi değeri Denklem 5’de gösterildiği hesaplanmaktadır.

$$H(p_1, p_2, \dots, p_s) = - \sum_{i=1}^s p_i \log(p_i) \quad (5)$$


Burada, s toplam sınıf sayısını, p_i , örnek bir verinin i . sınıfta olma olasılığını ifade etmektedir. H ise entropi değerini göstermektedir.

3. Deneysel Çalışmalar

Bu çalışmada, WiMax sistemleri için 3.5GHz ve 5.8GHz frekanslarında kullanılacak 50MHz-6GHz geniş bant InGaP HBT MMIC SBB5089Z GY modülünün DC besleme gerilim değerleri Arduino Uno geliştirme kartı kullanılarak 0V-5V arası 75mV’luk adımlarla (6 bit çözünürlük, $2^6=64$ adım ile) değiştirilmiştir. Değişen DC şartların GY doğrusal performans parametrelerini (S_{11} , S_{12} , S_{21} , S_{22}), nasıl değiştirdiği grafiksel olarak detaylı bir şekilde incelenmiştir. Ölçümlerde DC-6GHz Rohde&Schwarz FSH6 spektrum analizörü, DC güç kaynağı, güç bölmek ve güç izlemek için genişbant mikroşerit yönsel kuplör kullanılmıştır. Ölçümler sonucunda elde edilen veriler ile SBB5089Z RF GY modülünün farklı veri madenciliği metotları ile s-parametreleri modellenmiştir. Elde edilen modelleme sonuçları **R²**, **OKHK**, **OMH modelleme başarı ölçütlerine** göre karşılaştırılmış ve bu çalışmada kullanılmış olan SBB5089Z GY modülü için karşılaştırılan modeller arasından en iyi veri madenciliği modeli bulunmuştur.

3.1 Veri setinin oluşturulması

Çalışmada SBB5089Z GY modülü için iki farklı frekans (3.4GHz-3.6GHz ve 5.7GHz-5.9GHz) aralığındaki S_{11} , S_{12} , S_{21} ve S_{22} değişen DC koşullara göre ölçülmüştür. SBB5089Z GY modülü s-parametreleri ölçüm düzeneği Şekil 2’de gösterilmiştir.



Şekil 2. GY s-parametreleri ölçüm Düzeneği

Her bir parametre 0-5 volt aralığında altı bit çözünürlükle ($5 / 2^6$ voltluk adımlarla) ölçülmüştür. Frekans tarama aralığı 20 MHz'dir. Her bir frekans aralığında 11 veri setinden oluşan $11 \times 64 = 704$ veri bulunmaktadır. Modellemeler ise iki ayrı grupta toplam $704 \times 2 = 1408$ veri kullanılarak yapılmıştır.


3.2 Modellerin Oluşturulması

Çalışmada SBB5089Z GY modülünün frekans ve gerilim (V_{DC}) program girdilerine karşılık program çıktısı olarak dört farklı çıkış parametresi (S_{11} , S_{12} , S_{21} , S_{22}) için dört farklı tahmin modeli oluşturulmuş ve sonuçlar karşılaştırılmıştır. SBB5089Z GY modülün S_{11} giriş yansımaya katsayısı parametresi için modellerin başarı ölçütleri Tablo 1'de gösterilmiştir.

Tablo 1. S_{11} parametresi model sonuçları

Frekans (GHz)	Model	R^2	OKHK	OMH
3.4-3.6	k-EYK	0,9896	0,4745	0,2345
	YSA	0,9785	0,6814	0,5160
	K-star	0,9743	0,8216	0,6036
	SMOReg	0,6120	2,9023	2,4534
5.7-5.9	k-EYK	0,9992	0,3383	0,2336
	YSA	0,8595	4,5356	3,3126
	K-star	0,9434	3,0975	1,7312
	SMOReg	0,8095	5,5374	3,6795

Tablo 1'den görüldüğü üzere k-EYK algoritması S_{11} parametresi için 3.4GHz-3.6GHz&5.7GHz-5.9GHz frekanslarında diğer modellerden daha iyi sonuç vermiştir. Ayrıca elde edilen sonuçlar ile SBB5089Z GY modülü için S_{11} giriş yansımaya katsayısı parametresinin başarılı bir şekilde modellenebileceği gösterilmiştir. 3.4GHz-3.6GHz ve 5.7GHz-5.9GHz frekans aralıklarının modelleme başarıları kendi aralarında karşılaştırıldığı zaman k-EYK algoritmasının **R^2 , OKHK, OMH ölçütlerine göre** 5.7GHz-5.9GHz frekans aralığı için 3.4GHz-3.6GHz frekans aralığına göre daha başarılı sonuç verdiği gözlenmiştir. Şekil 3'te k-EYK'nın S_{11} parametresi için 5.7GHz-5.9GHz frekans aralığındaki ölçüm ve tahmin değerleri grafiği verilmiştir.

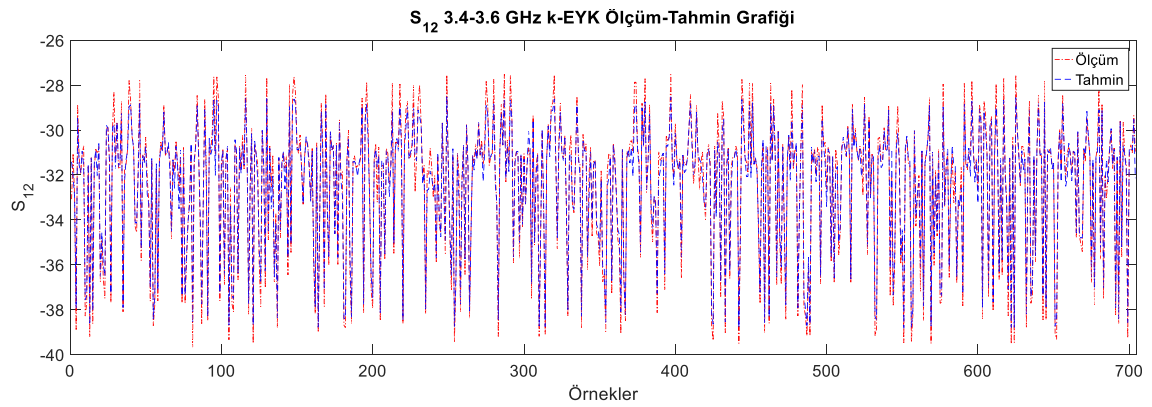


Şekil 3. S_{11} parametresinin 5.7GHz-5.9GHz frekans aralığındaki ölçüm-tahmin grafiği

SBB5089Z GY modülünün S_{12} geri iletim katsayısı için modelleme başarı ölçütleri karşılaştırması Tablo 2'de verilmiştir. Tablo 2'de SBB5089Z GY modülü için YSA ve k-EYK'nın birbirine yakın sonuçlar verdiği ancak k-EYK'nın daha başarılı olduğu görülmektedir. Şekil 4'te S_{12} parametresinin 5.7GHz-5.9GHz frekans aralığına göre daha başarılı olduğu 3.4GHz-3.6GHz frekans değerlerindeki k-EYK ölçüm ve tahmin değerleri grafiği gösterilmiştir.

Tablo 2. S_{12} parametresi model sonuçları

Frekans (GHz)	Model	R ²	OKHK	OMH
3.4-3.6	k-EYK	0,9943	0,2349	0,1200
	YSA	0,9912	0,2938	0,2054
	K-star	0,9830	0,5030	0,3718
	SMOReg	0,7035	1,7555	1,4176
5.7-5.9	k-EYK	0,9899	0,5700	0,3577
	YSA	0,9888	0,6050	0,4484
	K-star	0,9864	0,7683	0,5663
	SMOReg	0,8185	2,4570	1,9994



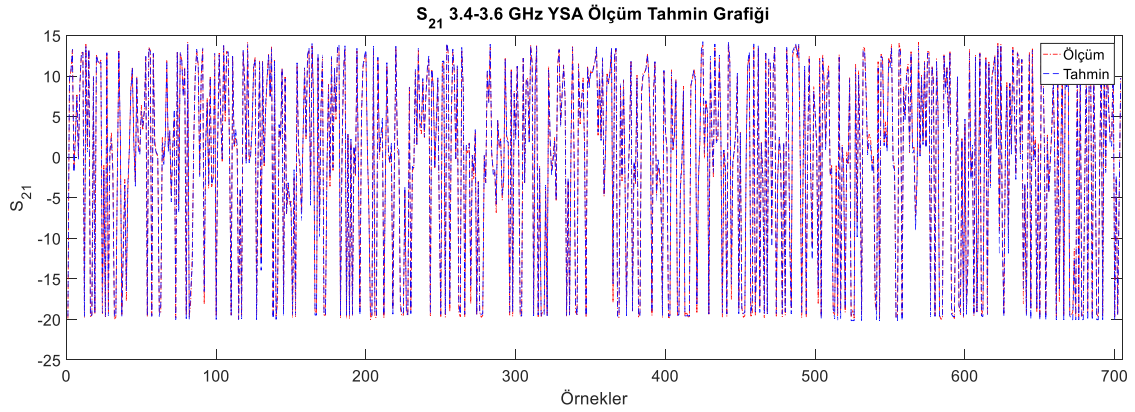
Şekil 4. S_{12} parametresinin 3.4GHz-3.6GHz frekans aralığındaki ölçüm-tahmin grafiği

Tablo 3'te ise SBB5089Z GY modülü için S_{21} kazanç parametresinin modelleme başarı sonuçları verilmiştir.

Tablo 3. S_{21} parametresi model sonuçları

Frekans (GHz)	Model	R ²	OKHK	OMH
3.4-3.6	k-EYK	0,9894	1,2550	0,4929
	YSA	0,9980	0,5502	0,4055
	K-star	0,9849	1,6892	1,2397
	SMOReg	0,9007	3,8528	3,1643
5.7-5.9	k-EYK	0,9742	2,8244	1,0699
	YSA	0,9891	1,8454	1,4306
	K-star	0,9597	3,8126	2,8169
	SMOReg	0,8300	7,3651	5,8233

Tablo 3 incelendiğinde SBB5089Z GY modülünün S_{21} kazanç parametresi için **R², OKHK, OMH modelleme başarı ölçütlerine göre** YSA modelinin en iyi sonucu verdiği görülmüştür. S_{11} ve S_{12} 'de olduğu gibi YSA, k-EYK ve KS modellerinin birbirine yakın sonuçlar verdiği gözlenmiştir. S_{21} parametresi için 3.4GHz-3.6GHz ve 5.7GHz-5.9GHz frekans aralıklarının modelleme başarıları kendi aralarında karşılaştırıldığı zaman YSA'nın **R², OKHK, OMH modelleme başarı ölçütlerine göre** 3.4GHz-3.6GHz frekans aralığında 5.7GHz-5.9GHz frekans aralığına göre daha iyi sonuç verdiği gözlenmiştir. Şekil 5'te 3.4-3.6GHz aralığında S_{21} parametresinin YSA modeli tahmin sonuçları ile ölçüm sonuçları grafiği verilmiştir.



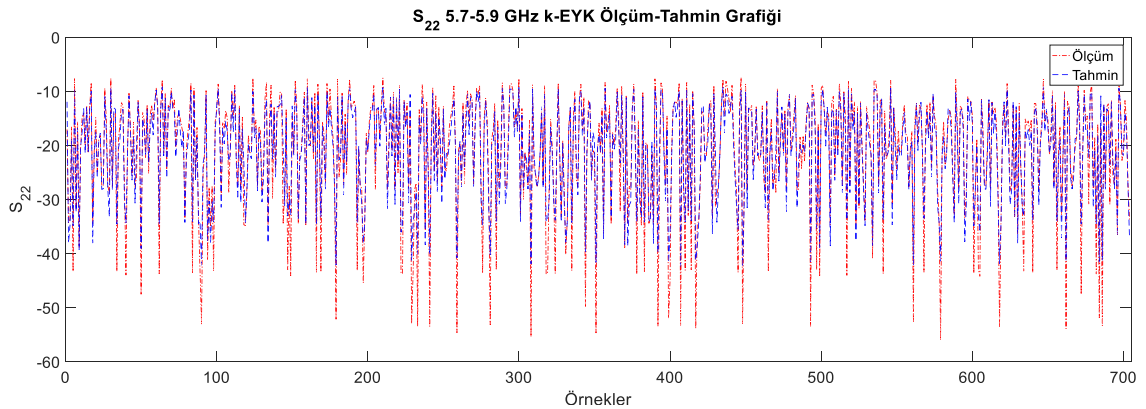
Şekil 5. 3.4-3.6GHz aralığında S_{21} parametresinin YSA modeli ölçüm-tahmin grafiği

Son olarak Tablo 4'te verilen SBB5089Z GY modülünün S_{22} çıkış yansıma katsayısı parametre modelleme sonuçları incelendiğinde 3.4GHz-3.6GHz frekansı aralığı için YSA'nın, 5.7GHz-5.9GHz frekans aralığı için ise k-EYK'nın en iyi sonuçları verdiği görülmüştür.

Tablo 4. S_{22} parametresi model sonuçları

Frekans (GHz)	Model	R^2	OKHK	OMH
3.4-3.6	k-EYK	0,9541	0,2854	0,1011
	YSA	0,9669	0,2413	0,1601
	K-star	0,9569	0,2906	0,1649
	SMOReg	0,7374	0,6933	0,5305
5.7-5.9	k-EYK	0,9909	1,0631	0,6004
	YSA	0,9689	1,9793	1,3794
	K-star	0,9104	3,7379	2,4188
	SMOReg	0,6117	7,2491	5,0165

Ancak oluşturulan modellerin S_{22} parametresi için 5.7GHz-5.9GHz aralığında daha başarılı sonuçlar verdiği tespit edilmiştir. Şekil 6'da, 5.7GHz-5.9GHz frekans aralığında S_{22} parametresinin k-EYK modeli için ölçüm-tahmin grafiği gösterilmiştir.



Şekil 6. 5.7-5.9GHz aralığında S_{22} parametresinin k-EYK modeli ölçüm-tahmin grafiği

Sonuçlar incelendiğinde 3.4GHz-3.6GHz&5.7GHz-5.9GHz frekans aralıklarında SBB5089Z GY modülü S_{11} , S_{12} , S_{21} , S_{22} parametrelerinin veri madenciliği yöntemleri ile modellenebileceği görülmektedir. Bu çalışmada kullanılan modelleme sonuçları R^2 , **OKHK**, **OMH başarı ölçütlerine göre değerlendirildiğinde** SMOReg algoritmasının SBB5089Z GY modülü s-parametreleri modellemesi için diğer modellerin gerisinde kaldığı anlaşılmıştır. SBB5089Z GY modülü S_{11} , S_{12} , S_{21} ve S_{22} parametreleri için en uygun modelleme yönteminin k-EYK modeli olduğu, bazı

durumlarda ise YSA modelinin k-EYK modelinden daha iyi olduğu görülmüştür. Genel olarak bakıldığında zaman, k-EYK, YSA ve KS algoritmalarının bu çalışmada kullanılan SBB5089Z GY modülü doğrusal performans parametreleri olan S_{11} , S_{12} , S_{21} ve S_{22} 'yi modellemede başarılı bir şekilde kullanılabileceği gösterilmiştir.

Son olarak benzer GY'lerin de bu çalışmada kullanılan veri madenciliği metotları ile modellenebileceğinin gösterilebilmesi amacıyla SGA-4186(Z) RF GY modülünün s-parametreleri (S_{11} , S_{12} , S_{21} , S_{22}) ($V_{DC}=0V:0.75V:3.2V$) için 3.5GHz-5GHz frekans aralığında YSA, SMOReg, k-EYK, KS algoritmaları ile ayrı ayrı modellenmiştir. Her bir s-parametresi için (S_{11} , S_{12} , S_{21} , S_{22}) modelleme sonuçları Tablo 5'te gösterilmiştir. Tablo 5'e göre SGA-4186(Z) RF GY modülü giriş yansıma katsayısı (S_{11}), çıkış yansıma katsayısı (S_{22}) ve kazancı(S_{21}) için k-EYK algoritması, ileri iletim katsayısı olan (S_{12}) için ise YSA en iyi modelleme sonuçlarını vermiştir. SGA-4186(Z) RF GY modülü S_{11} , S_{21} , S_{22} doğrusal performans parametreleri için k-EYK ve YSA algoritmaları hariç SMOReg, KS algoritmalarının da birbirine yakın başarılı sonuçlar verdiği gözlenmiştir. Yalnızca S_{12} için SMOReg algoritmasının modelleme başarısının k-EYK, KS ve YSA'ya oranla daha düşük olduğu gözlenmiştir. Elde edilen sonuçlara göre SBB5089Z GY modülünde olduğu gibi SGA-4186(Z) GY modülü s-parametrelerinin de 3.5GHz-5GHz frekans aralığında veri madenciliği metotları ile başarılı bir şekilde modellenebileceği görülmüştür. Elde edilen sonuçlar YSA, SMOReg, k-EYK, KS algoritmalarının benzer RF GY modülleri s-parametreleri modellemesinde kullanılabileceğini ve bu çalışmanın tekrar edilebilir olduğunu göstermiştir.

Tablo 5. SGA-4186(Z) RF GY S_{11} , S_{12} , S_{21} , S_{22} model sonuçları

Parametre	Model	R ²	OKHK	OMH
S_{11}	k-EYK	0.9658	1.1281	0.9777
	YSA	0.8661	2.166	1.8706
	K-star	0.8692	2.7495	2.3076
	SMOReg	0.9194	1.7787	1.4482
S_{21}	k-EYK	0.9971	0.0651	0.051
	YSA	0.9961	0.0755	0.0615
	K-star	0.9751	0.27	0.1814
	SMOReg	0.9705	0.2079	0.1733
S_{12}	k-EYK	0.9936	0.1162	0.0914
	YSA	0.9946	0.1103	0.0879
	K-star	0.9823	0.201	0.1291
	SMOReg	0.6158	0.8783	0.6564
S_{22}	k-EYK	0.9553	1.3907	1.0761
	YSA	0.9508	1.3773	0.9834
	K-star	0.938	1.5873	1.3595
	SMOReg	0.9194	1.7787	1.4482

4. Sonuç

Bu çalışmada öncelikle 3.4GHz-3.6GHz&5.7GHz-5.9GHz frekans aralıklarında, değişen DC koşullara göre 0GHz-6GHz geniş bant SBB5089Z GY modülünün s-parametreleri (S_{11} , S_{21} , S_{22} , S_{12}) ölçülmüştür. SBB5089Z GY modülünün DC şartları V_{DC} [0V:0.075V:5V] aralığında değiştirilmiştir. Frekans tarama aralığı ise 20MHz seçilmiştir. S-parametreleri ölçümlerinden elde edilen veriler YSA, SMOReg, k-EYK, KS ile ayrı ayrı modellenmiş, modelleme başarıları R², OKHK ve OMH başarı ölçütleri ile karşılaştırılmıştır.

Elde edilen modelleme sonuçlarına göre SBB5089Z GY modülü S_{11} giriş yansıma katsayısı parametresi için 3.4GHz-3.6GHz&5.7GHz-5.9GHz frekans aralıklarında k-EYK algoritmasının en iyi sonucu verdiği görülmüştür. Benzer şekilde SBB5089Z GY modülü geri iletim katsayısı olan S_{12} için 3.4GHz-3.6GHz&5.7GHz-5.9GHz frekans aralıklarında YSA ve k-EYK'nın birbirine yakın sonuçlar verdiği ancak k-EYK'nın daha başarılı olduğu, S_{21} için YSA'nın en iyi sonuç verdiği ve son olarak S_{22} için ise YSA ile k-EYK'nın en iyi modelleme sonuçlarını verdiği gözlenmiştir.

SBB5089Z GY modülü s-parametre modellemelerine genel olarak bakıldığında S_{11} , S_{12} , S_{21} ve S_{22} parametreleri için en uygun modelleme yönteminin k-EYK modeli olduğu tespit edilmiştir. Ancak

sonuçlardan anlaşıldığı üzere YSA ve KS algoritmalarının da SBB5089Z GY modülü doğrusal performans parametreleri olan S_{11} , S_{12} , S_{21} ve S_{22} modellenmesinde k-EYK'nın alternatifi olarak kullanılabileceği gösterilmiştir. Sonuç olarak bu çalışmada SBB5089Z GY modülü doğrusal performans parametrelerinden olan s-parametrelerinin (S_{11} , S_{12} , S_{21} , S_{22}) veri madenciliği yöntemleri ile modellenebileceği gösterilmiştir.

Çalışmada ayrıca SBB5089Z GY modülü dışında, SGA4186(Z) GY modülü s-parametreleri de (S_{11} , S_{12} , S_{21} , S_{22}) 3.5GHz-5GHz frekans aralığında YSA, SMOReg, k-EYK, KS algoritmaları ile ayrı ayrı modellenmiş ve başarılı sonuçlar elde edilmiştir. Benzer GY s-parametreleri modellenmelerinin YSA, SMOReg, k-EYK, KS algoritmaları ile yapılabileceği gösterilerek çalışmanın tekrar edilebilir olduğu ispatlanmıştır.

5. Kaynaklar

Ade, Roshani, and P. R. Deshmukh. 2014. "Classification of Students by Using an Incremental Ensemble of Classifiers." In *Proceedings of 3rd International Conference on Reliability, Infocom Technologies and Optimization*, IEEE, 1–5.

Çakır, Abdülkadir, Hakan Çalış, and Ecir U. Küçüksille. 2009. "Data Mining Approach for Supply Unbalance Detection in Induction Motor." *Expert Systems with Applications* 36(9): 11808–13.

David M. Pozar. 2012. *Microwave Engineering*.

Fisher, Paul O., and Said F. Al-Sarawi. 2016. "Memoryless AM/AM Behavioral Model for RF Power Amplifiers." In *2016 3rd Asia-Pacific World Congress on Computer Science and Engineering (APWC on CSE)*, IEEE, 131–38.

Hayati, Mohsen, Farzin Shama, Sobhan Roshani, and Abdolali Abdipour. 2014. "Linearization Design Method in Class-F Power Amplifier Using Artificial Neural Network." *Journal of Computational Electronics* 13(4): 943–49.

Juarez-Cazares, S. A. et al. 2016. "FPGA-Based Modeling and Design Methodology of a Digital Pre-Distortion System for Power Amplifier Linearization." In *2016 International Conference on Mechatronics, Electronics and Automotive Engineering (ICMEAE)*, IEEE, 113–18.

Ko, Youngseo et al. 2014. "Artificial Neural Network Model of SOS-MOSFETs Based on Dynamic Large-Signal Measurements." *IEEE Transactions on Microwave Theory and Techniques* 62(3): 491–501.

Kucuk, H., C. Tepe, and I. Eminoglu. 2013. "Classification of EMG Signals by K-Nearest Neighbor Algorithm and Support Vector Machine Methods." In *2013 21st Signal Processing and Communications Applications Conference (SIU)*, IEEE, 1–4.

Long, Yunshen, Zheng Zhong, and Yong-Xin Guo. 2016. "A Novel 4-D Artificial-Neural-Network-Based Hybrid Large-Signal Model of GaAs pHEMTs." *IEEE Transactions on Microwave Theory and Techniques* 64(6): 1752–62.

Nunez-Perez, J. C. et al. 2016. "FPGA Realization of RF-PA Models with Memory Effects Based on ANFIS." In *2016 IEEE International Autumn Meeting on Power, Electronics and Computing (ROPEC)*, IEEE, 1–6.

Platt, John. 1998. "Fast Training of Support Vector Machines Using Sequential Minimal Optimization."

Renteria-Cedano, J. A., L. M. Aguilar-Lobo, J. R. Loo-Yau, and S. Ortega-Cisneros. 2014. "Implementation of a NARX Neural Network in a FPGA for Modeling the Inverse Characteristics of Power Amplifiers." In *2014 IEEE 57th International Midwest Symposium on Circuits and Systems (MWSCAS)*, IEEE, 209–12.

Ricardo Cárdenas-Valdez, José et al. 2015. "Modeling Memory Effects in RF Power Amplifiers Applied

to a Digital Pre-Distortion Algorithm and Emulated on a DSP-FPGA Board.” *Integration, the VLSI Journal* 49: 49–64.

Saad, Paul. 2006. “Design a Highly Linear Power Amplifier Based on HBT Master’s Thesis in Electronics/Telecommunication.”, *University of Gavle*.

Senel, Bilge, Mehmet Fatih Caglar, and Fatih Ahmet Senel. 2016. “Behavioral Modeling of 2.4GHz RF Power Amplifier Using Data Mining.” *Conference: 2nd International Conference on Engineering and Natural Sciences (ICENS 2016), At Sarajevo* 10.

Yuan, Xiao-Hui, and Quanyuan Feng. 2013. “BEHAVIORAL MODELING OF RF POWER AMPLIFIERS WITH MEMORY EFFECTS USING ORTHONORMAL HERMITE POLYNOMIAL BASIS NEURAL NETWORK.” *Progress In Electromagnetics Research C* 34: 239–51.