

Farklı Öğrenme Algoritmaları Kullanılarak Eğitilen Yapay Sinir Ağları İle Elektriksel Olarak İnce ve Kalın Dikdörtgen Mikroşerit Antenlerin Rezonans Direncinin Hesaplanması

S. Sinan Gültekin, Kerim Güney*, Şeref Sağıroğlu**
Selçuk Üniversitesi
Mühendislik Mimarlık Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü,
42300, Konya
sgultekin@selcuk.edu.tr

*Erciyes Üniversitesi
Mühendislik Fakültesi, Elektronik Bölümü,
38039, Kayseri
kguney@erciyes.edu.tr

**Erciyes Üniversitesi
Mühendislik Fakültesi, Bilgisayar Bölümü,
38039, Kayseri
ss@erciyes.edu.tr

Özet: Elektriksel olarak hem ince hem de kalın dikdörtgen mikroşerit antenlerin rezonans direnci yapay sinir ağlarına (YSA) dayanan bir yöntem ile hesaplanmıştır. YSA'ların eğitilmesinde çok katlı perseptronlar ve radyal tabanlı yapı üzerinde farklı öğrenme yöntemleri kullanılmış ve bu yöntemlerin performansları karşılaştırılmıştır. Eğitim ve test işleminde literatürde mevcut 33 farklı dikdörtgen mikroşerit antene ait rezonans direnci ölçme verileri kullanılmıştır. Nöral modellerden elde edilen sonuçların, literatürde mevcut olan klasik yöntemlerin sonuçlarından çok daha iyi deneysel sonuçlarla uyumluluk içinde olduğu gösterilmiştir. Burada kullanılan nöral modellerin avantajları, kolaylıkla uygulanabilmesi ve elde edilen sonuçların doğruluğudur.

1.Giriş

Mikroşerit antenlerin tasarımında besleme ve yama arasında iyi bir uyum sağlamak için mikroşerit antenlerin rezonans direncinin doğru olarak belirlenmesi gereklidir. Rezonans direnci, antenden veya antene enerji transferini doğrudan etkiler. En popüler ve en yaygın olarak kullanılan mikroşerit anten tiplerinden biri olan dikdörtgen mikroşerit antenlerin rezonans direncini hesaplamak için literatürde mevcut olan yöntemlerin çoğu, yalnız elektriksel olarak ince mikroşerit antenler için geçerlidir [1]-[2]. Elektriksel olarak ince dikdörtgen mikroşerit antenlerin band genişliği düşüktür. Bu tür antenlerin band genişliğini artırmak için kullanılacak tekniklerden biri, uygun bir şekilde dielektrik taban kalınlığını artırmaktır. Ancak, elektriksel olarak kalın dikdörtgen mikroşerit antenlerin rezonans direncinin belirlenmesinde hesaba dahil edilmesi gereken yüzey dalga ışınım direncinin kesin olarak belirlenebilmesi, karmaşık ve zor olan integral dönüşüm teknikleri ve Green fonksiyon yöntemleri ile yapılabilmektedir [1]-[2]. Ayrıca, literatürdeki mevcut klasik ve nümerik yöntemlerle elektriksel olarak hem ince hem de kalın dikdörtgen mikroşerit antenlerin rezonans direnci için elde edilen teorik sonuçlar, deneysel sonuçlarla iyi bir uyumluluk içerisinde değildir. Bu sebepten dolayı bu çalışmada, öğrenme yeteneği, kolayca farklı problemlere uyarlanabilirliği, genelleme yapabilmesi, daha az bilgi gerektirmesi, paralel yapılarından dolayı hızlı çalışabilme yeteneği ve kolay bir şekilde uygulanabilmesi gibi pek çok avantajından dolayı yapay sinir ağlarına (YSA) dayanan bir yöntem, elektriksel olarak hem ince hem de kalın dikdörtgen mikroşerit antenlerin rezonans direncini hesaplamak için sunulmuştur.

Bu çalışmada, YSA'ların eğitilmesinde çok katlı perseptronlar (ÇKP) [3] ve radyal tabanlı yapı (RTY) [4] üzerinde farklı öğrenme yöntemleri kullanılmış ve bu yöntemlerin performansları karşılaştırılmıştır. Yönlendirilmiş rasgele arama (YRA) [5], genetik algoritma (GA) [6], Levenberg-Marquardt (LM) [7]-[8], eşleştirmeli gradyent Fletcher-Reeves (FR) [9], eşleştirmeli gradyent Polak-Ribière (PR) [10], eşleştirmeli

gradyent Powell-Beale (PB) [11], ölçeklendirilmiş eşleştirmeli gradyent (ÖEG) [12], adaptif öğrenme oranlı geri yayılım (AGY) [10], momentumlu geri yayılım (MGY) [10], Broyden-Fletcher-Goldfarb-Shanno (BFGS) [13], tek adım secant (TAS) [14], esnek geri yayılım (EGY) [15] ve otomatik düzenleme (OD) [16] algoritması gibi farklı 13 öğrenme yöntemi kullanılarak ÇKP'ler, genişletilmiş delta-bar-delta (GDBD) [17] algoritması kullanılarak da RTY yapı eğitilmiştir. Farklı öğrenme algoritmaları kullanmanın amacı, daha hızlı ve daha doğru sonuç elde etmek ve farklı öğrenme yöntemlerini ve ağlarını bu tip uygulamalar için test etmektir. Nöral modellerden elde edilen sonuçlar, hem deneysel sonuçlarla hem de literatürdeki mevcut yöntemlerin sonuçları ile karşılaştırılmıştır. Bu çalışmada sunulan tüm nöral modellerden elde edilen sonuçların, literatürde mevcut olan klasik yöntemlerin sonuçlarından çok daha iyi deneysel sonuçlarla uyumluluk içinde olduğu görülmüştür.

2. Yapay Sinir Ağları

YSA biyolojik sinir sisteminin çalışma prensibi temel alınarak geliştirilmiştir [3]. YSA, yapay sinir hücrelerinin birbirleri ile çeşitli şekillerde bağlanmasından oluşur ve genellikle katmanlar şeklinde düzenlenir. YSA'ların bir çok yapısı mevcuttur [3], [18]-[19]. Bu yapılardan ÇKP ve RTY bu çalışmada dikdörtgen mikroşerit antenlerin rezonans direncini hesaplamak için kullanılmıştır.

ÇKP'ler en çok kullanılan YSA yapısıdır. ÇKP bir giriş katmanı, bir veya birden fazla ara katman ve bir çıkış katmanından oluşan ileri beslemeli bir YSA tipidir. Giriş katmanındaki işlemci elemanlar sadece giriş sinyallerini ara katmandaki işlemci elemanlara dağıtan bir tampon görevi görür. Ara kat işlemci elemanları bir önceki katın çıkışlarını giriş olarak kullanır. Tüm girişlerle ağırlıklar çarpılarak toplanır. Daha sonra toplanan bu değer bir transfer fonksiyonundan geçirilerek o nöronun çıkış değeri hesaplanır. Bu işlemler bu kattaki bütün işlemci elemanlar için tekrarlanır. Çıkış katmanındaki işlemci elemanlarda, ara katman elemanları gibi davranırlar ve ağ çıkış değerleri hesaplanır. Bir çok öğretim algoritmasının ÇKP ağını eğitmede kullanılabilir olması, bu ağın yaygın olarak kullanılmasının sebebidir. Bu çalışmada YRA, GA, LM, FR, PR, PB, ÖEG, AGY, MGY, BFGS, TAS, EGY ve OD algoritmaları ÇKP'lerin eğitilmesinde kullanılmıştır.

RTY, ÇKP'ye alternatif bir YSA yapısı olarak geliştirilmiş ve genellikle modelleme ve sınıflandırma uygulamalarında kullanılmıştır [4]. Bu ağ tipi, genellikle, radyal olarak alternatif arakat işlemci elemanlarının dahili olarak temsil edilmesiyle oluşan bir ağ olarak bilinir. Bu işlemci elemanda temel olarak üç özellik bulunur. Bu özellikler; giriş ve ara katmanlar arasında ağırlık vektörü olarak saklanan giriş uzayındaki bir merkez vektörü, giriş vektörünün merkezden ne kadar uzak olduğunu belirleme de kullanılan mesafe ifadesi (Öklit uzaklığı) ve tek değişkenli olan ve uzaklık fonksiyon çıkışını giriş olarak alan işlemci elemanın çıkış değerini belirleyen bir aktivasyon (transfer) fonksiyonu olarak sıralanabilir. Bu yapıda öğrenme, yığın merkezlerini (cluster centres) ve en yakın komşuluğu (nearest neighbour heuristic) karşılaştırarak gerçekleştirilir. Ara katman işlemci eleman fonksiyonlarının merkezi konumlarının belirlenmesi için literatürde bazı yöntemler önerilmiştir [3]. Lineer regresyon veya geri-yayılım algoritmaları ile ara katman arasındaki ağırlıkları hesaplamak mümkündür. Bu çalışmada, GDBD algoritması çıkış ile ara katman arasındaki ağırlıkları hesaplamak için kullanılmıştır.

3. Dikdörtgen Mikroşerit Antenin Rezonans Direncinin YSA ile Hesabı

Dikdörtgen mikroşerit antenin rezonans direncinin YSA ile hesaplanmasında kullanılan YSA modelinin girişleri, yama uzunluğu L , yama genişliği W , besleme noktasının yama kenarına olan uzaklığı a , kayıp tanjantı $\tan\delta$ ve dielektrik taban kalınlığının dielektrik tabandaki dalga boyuna oranı h/λ_d 'dir. YSA'ları eğitmek ve test etmek için, Tablo 1'de verilen ölçme verileri [20]-[21] kullanılmıştır.

Bu çalışmada sunulan nöral modellerden elde edilen rezonans direnci sonuçları Tablo 1'de, bu modellerin epok ve ara kat nöron sayıları ile nöral modellerden hesaplanan sonuçlarla ölçülen rezonans dirençleri arasındaki mutlak hatalar Tablo 2'de verilmiştir. Literatürdeki mevcut klasik yöntemlerden [21]-[23] ve GDBD, delta bar delta (DBD), geri yayılım (GY) ve hızlı yayılım (HY) algoritmaları ile eğitilen nöral modellerden [24] hesaplanan sonuçlarla ölçülen rezonans dirençleri arasındaki mutlak hataların toplamı da Tablo 3'de sunulmuştur. Tablo 2 ve 3'den görüldüğü gibi literatürdeki mevcut klasik yöntemlerdeki en düşük toplam mutlak hata 455 Ohm iken bu çalışmada sunulan LM ile eğitilen ÇKP yapısından elde edilen toplam mutlak hata, 5 Ohm'dur. Bunu 7 Ohm ile FR, 8 Ohm ile OD ve 9 Ohm ile BFGS algoritmaları ile eğitilen ÇKP ağ yapıları takip etmiştir. Bu çalışmada ve [24]'de sunulan tüm nöral modellerden elde edilen sonuçların, literatürde mevcut olan klasik yöntemlerin sonuçlarından çok daha iyi deneysel sonuçlarla uyumluluk içinde olduğu görülmektedir.

4. Sonuç

Dikdörtgen mikroşerit antenlerin rezonans direncini hesaplamak için, YSA'ya dayanan bir yöntem sunulmuştur. YSA ağı yapılarından ÇKP'lerin eğitilmesinde YRA, GA, LM, FR, PR, PB, ÖEG, AGY, MGY, BFGS, TAS, EGY ve OD algoritmaları, RTY'nin eğitilmesinde ise GDBD algoritması kullanılmıştır. LM ile eğitilen ÇKP yapısından en iyi sonuç elde edilmiştir. Bu çalışmada ve literatürde sunulan tüm nöral sonuçların, literatürde mevcut olan diğer klasik yöntemlerin sonuçlarından çok daha iyi deneysel sonuçlarla uyumluluk içinde olduğu gösterilmiştir. Nöral modellerin avantajları, kolaylıkla uygulanabilmeleri ve elde edilen sonuçların doğruluğudur.

Tablo 1. Dikdörtgen mikroşerit antenler için ölçülen rezonans rezonans dirençleri ile nöral modeller kullanılarak hesaplanan rezonans dirençlerinin karşılaştırılması.

a (mm)	W (mm)	L (mm)	tanδ	h/λ _d	Ölçülen [20, 21] R _r (Ohm)	ÇKP										RTY				
						YRA	GA	LM	BFGS	OD	ÖEG	EGY	TAS	PB	PR	FR	AGY	MGY	GDBD	
4.15	8.50	12.90	0.001	0.0065	58	54	53	58	58	58	58	58	58	58	58	58	58	58	58	58
4.10	7.90	11.85	0.001	0.0071	44	51	49	44	44	45	44	44	44	44	44	44	44	44	44	44
*6.27	18.10	19.60	0.001	0.0384	58	58	58	58	60	58	59	56	63	57	57	58	62	63	67	67
6.83	20.00	25.00	0.001	0.0155	89	89	89	89	89	89	89	89	89	89	89	89	89	89	89	89
3.90	10.63	11.83	0.002	0.0326	54	54	54	54	54	54	54	54	54	54	54	54	54	54	54	54
3.75	9.10	10.00	0.001	0.0622	56	56	55	56	56	56	56	56	56	56	56	56	56	56	56	56
5.94	17.20	18.60	0.001	0.0404	58	58	58	58	58	58	58	58	58	58	58	58	58	58	58	58
4.25	12.70	13.50	0.002	0.0569	64	65	64	64	64	64	64	64	64	64	64	64	64	64	64	64
*4.75	13.37	14.12	0.002	0.0666	52	52	53	52	53	52	53	55	50	53	56	51	54	46	57	57
5.28	15.00	16.21	0.002	0.0486	53	53	53	53	53	53	53	53	53	53	53	53	53	53	53	53
4.25	11.20	12.00	0.002	0.0908	46	47	46	46	46	46	46	46	46	46	46	46	46	46	46	46
4.60	14.03	14.85	0.002	0.0778	70	69	71	70	70	70	70	70	70	70	70	70	70	70	70	70
4.70	15.30	16.30	0.002	0.0833	86	86	85	86	86	86	86	86	86	86	86	86	86	86	86	86
3.40	11.70	12.80	0.002	0.1039	110	110	110	110	110	110	110	110	110	110	110	110	110	110	110	110
*5.82	13.75	15.80	0.002	0.1292	44	44	41	44	46	45	44	43	44	45	43	45	52	43	51	51
3.70	9.05	10.18	0.002	0.1263	46	46	47	46	46	46	46	46	46	46	46	46	46	46	46	46
4.03	7.76	10.80	0.002	0.1405	47	44	45	47	47	47	47	47	47	47	47	47	47	47	47	47
3.00	7.90	12.55	0.002	0.1519	46	47	47	46	46	46	46	46	46	46	46	46	46	46	46	46
3.75	9.87	14.50	0.002	0.1454	46	45	45	46	46	46	46	46	46	46	46	46	46	46	46	46
3.10	8.14	14.40	0.002	0.1617	46	45	46	46	46	45	45	46	45	46	46	46	46	46	46	46
3.50	7.90	16.20	0.002	0.1754	45	45	45	45	45	45	46	45	45	46	45	45	45	45	45	45
*3.45	10.00	15.20	0.002	0.1475	45	45	46	47	45	46	53	39	47	46	46	47	49	52	49	49
2.55	12.00	19.70	0.002	0.1553	44	46	44	44	44	45	44	43	45	44	44	44	44	44	44	44
4.25	7.83	23.00	0.002	0.2091	46	45	46	46	46	45	46	46	46	46	46	46	46	46	46	46
*3.20	12.56	27.56	0.002	0.1814	46	45	45	44	43	45	46	45	44	44	44	44	54	43	45	45
3.10	9.74	26.20	0.002	0.2017	45	45	45	45	45	45	45	46	45	46	45	45	45	45	45	45
3.55	10.20	26.40	0.002	0.1976	45	45	45	45	45	45	45	44	45	44	45	45	45	45	45	45
3.05	8.83	26.76	0.002	0.2119	46	46	46	46	46	46	46	47	46	47	46	46	46	46	46	46
3.20	7.77	28.35	0.002	0.2284	49	49	49	49	49	49	49	48	49	48	49	49	49	49	48	49
*3.60	10.30	33.80	0.002	0.2182	47	47	48	48	48	48	48	47	48	48	48	48	47	48	48	48
3.00	9.20	31.30	0.002	0.2216	50	50	48	50	50	50	50	49	50	49	50	50	50	50	50	50
3.70	12.65	35.00	0.002	0.2032	46	46	46	46	46	46	46	47	46	47	46	46	46	46	46	46
3.70	10.80	34.00	0.002	0.2148	47	47	48	47	47	47	47	47	47	47	47	47	47	47	47	47

* Test verileri

Tablo 2. Kullanılan nöral modellerin ara kat nöron, epok sayıları ve ölçülen rezonans dirençleri ile nöral modeller kullanılarak hesaplanan rezonans dirençleri arasındaki mutlak hatalar

Nöral Modeller	Katlardaki Nöron Sayısı			Eğitim İçin Epok Sayısı	Eğitim Mutlak Hata (Ohm)	Test Mutlak Hata (Ohm)	Toplam Mutlak Hata (Ohm)
	1.kat	2.kat	3.kat				
ÇKP-YRA	10	2	-	1850	23	1	24
ÇKP-GA	30	12	-	1100	21	7	28
ÇKP-LM	4	8	3	250	0	5	5
ÇKP-BFGS	20	12	7	350	0	9	9
ÇKP-OD	5	3	3	170	4	4	8
ÇKP-ÖEG	10	7	7	1200	2	11	13
ÇKP-EGY	5	4	-	30000	7	13	20
ÇKP-TAS	7	5	-	30000	2	12	14
ÇKP-PB	8	7	5	550	7	7	14
ÇKP-PR	18	10	2	1800	0	10	10
ÇKP-FR	7	5	-	4000	0	7	7
ÇKP-AGY	30	30	8	15000	2	26	28
ÇKP-MGY	25	35	7	20000	4	23	27
RTY-GDBD	35	15	-	14800	0	27	27

Tablo 3. Ölçülen rezonans dirençleri ile literatürde mevcut klasik ve nöral yöntemler kullanılarak hesaplanan rezonans dirençleri arasındaki mutlak hataların toplamı.

Toplam Mutlak Hata (Ω)	[21]	[22]	[23]	ÇKP/GDBD [24]	ÇKP/DBD [24]	ÇKP/GY [24]	ÇKP/HY [24]
	455	22343	7904	10	13	10	21

Kaynaklar

- [1]. Lee K.F. ve Chen W., Advances in Microstrip and Printed Antennas. John Wiley and Sons, 1997.
- [2]. Garg R., Bhartia P., Bahl I.J. ve Ittipiboon A., Microstrip Antenna Design Handbook. Dedham MA.: Artech House, 2000.
- [3]. Haykin S., Neural Networks: A Comprehensive Foundation. Macmillan College Publishing Company, New York, 1994.
- [4]. Moody J. ve Darken C., “Fast-learning in networks of locally-tuned processing units”, Neural Computation, 1, s.281-294, 1989.
- [5]. Matyas J., “Random Optimization, Automation and Remote Control”, 26, s.246-253, 1965.
- [6]. Holland J.H., Adaptation in Natural and Artificial Systems. The University of Michigan Press., Ann Arbor, MI., 1975.
- [7]. Levenberg K., “A method for the solution of certain nonlinear problems in least squares”, Quart. Appl. Math., 2, s.164-168, 1944.
- [8]. Marquardt D.W., “An algorithm for least-squares estimation of nonlinear parameters”, J. Soc. Ind. Appl. Math., 11, s.431-441, 1963.
- [9]. Fletcher R., Reeves C.M., “Function minimization by conjugate gradients”, Computer Journal, 7, s.149-154, 1964.
- [10]. Hagan M.T., Demuth H.B. ve Beale M., Neural Network Design. Boston PWS Publishing Company, 1996.
- [11]. Powell M.J.D., “Restart procedures for the conjugate gradient method”, Mathematical Programming, 12, s.241-254, 1977.
- [12]. Fletcher R., Practical Methods of Optimization. John Wiley & Sons, 1987.
- [13]. Himmelblau D.M., Applied Nonlinear Programming. McGraw-Hill, 1972.
- [14]. Battiti R., “First and second order methods for learning: between steepest descent and newton’s method”, Neural Computation, 4, s.141-166, 1992.
- [15]. Anderson C., Learning and Problem Solving with Multilayer Connectionist Systems. Technical Report COINS TR 86-50, University of Massachusetts, Amherst, MA., 1986.
- [16]. MacKay D.J.C., “Bayesian interpolation”, Neural Computation, 4(3), s.415-447, 1992.
- [17]. Minai A.A. ve Williams R.D., “Acceleration of backpropagation through learning rate and momentum adaptation,” International Joint Conference on Neural Networks, 1990, 1, s.676-679.
- [18]. NeuralWare Handbook, Neural Computing: A Technology Handbook for Professional II/PLUS and NeuralWorks Explorer. Pittsburgh. USA., 1996.
- [19]. Mathworks Inc., Matlab 5.3 Neural Network Toolbox, Users Guide, 5. Printing, Version 3, Mathworks Inc., 1998.
- [20]. Kara M., “An efficient technique for the computation of the input resistance of rectangular microstrip antenna elements with thick substrates”, Microwave and Optical Technology Letters, 13, s.363-369, 1996.
- [21]. Kara M., “The calculation of the input resistance of rectangular microstrip antenna elements with various substrate thicknesses”, Microwave and Optical Technology Letters, 13, s.137-142, 1996.
- [22]. Carver K.R., “A modal expansion theory for the microstrip antenna”, IEEE AP-S Int. Symposium Digest, 1979, s.101-104.
- [23]. Güney K., “Radiation quality factor and resonant resistance of rectangular microstrip antennas”, Microwave and Optical Technology Letters, 7, s.427-430, 1994.
- [24]. Güney K., Erler M. ve Sağıroğlu S., “Artificial neural networks for the resonant resistance calculation of electrically thin and thick rectangular microstrip antennas”, Electromagnetics, 20, s.387-400, 2000.