

FARKLI YAPAY SİNİR AĞLARI YÖNTEMLERİNİ KULLANARAK KURU TİP TRANSFORMATÖR SARGISININ TERMAL ANALİZİ

Dildade AŞKIN, İres İSKENDER, Ali MAMIZADEH

Elektrik-Elektronik Mühendisliği Bölümü, Mühendislik Fakültesi, Gazi Üniversitesi, Maltepe, 06570, Ankara
daskin@ilbank.gov.tr, iresis@gazi.edu.tr, mamizadeh@gazi.edu.tr

(Geliş/Received: 14.04.2011; Kabul/Accepted: 22.08.2011)

ÖZET

Yapay sinir ağları (YSA), uygulamalarda ve farklı disiplinlerdeki karmaşık problemlerin analizinde sıklıkla kullanılan bir modelleme aracı haline gelmiştir. Bu çalışmada, kuru tip transformatör sargısının termal modeli üç farklı YSA yapısı kullanılarak modellenmiş ve bu modelleme ile ilgili en başarılı ağ yapısı belirlenmiştir. Termal modelleme analizinde kullanılan sinir ağ modelleri; i- ileri beslemeli ağ yapısına sahip olan çok katmanlı sinir ağı, ii- geri besleme ağ yapısına sahip olan Elman ağı ve iii- Harici girişlerle birlikte lineer olmayan özbağlanımlı ağ modelleri kullanılmıştır. Ayrıca üç YSA modeline, Levenberg-Marquardt ve Bayesian Regulation eğitim algoritmaları uygulanmış ve sonuçlar karşılaştırılmıştır. Aynı ağ yapısı ve aynı eğitim algoritması, 5 KVA ve 3KVA 'lık transformatörlerden alınan iki farklı deney seti verileri için uygulanmıştır. Performans belirleyici faktörü kullanarak sinir ağ yapıları ve eğitim algoritmaları değerlendirilmiştir. Kuru tip transformatör sargısının termal analizinde kullanılan sonuçların karşılaştırılmasında en iyi yapay sinir ağ modeli NARX ve en iyi eğitim algoritması Bayesian Regulation olarak belirlenmiştir.

Anahtar Kelimeler: Kuru tip transformatör, yapay sinir ağları, dinamik modelleme, geri besleme

DRY TYPE TRANSFORMER WINDING THERMAL ANALYSIS USING DIFFERENT NEURAL NETWORK METHODS

ABSTRACT

Artificial Neural Network (ANN) has become a modeling tool frequently used in applications and analyzing the complex problems in different disciplines. In this study, the thermal model of dry type transformer winding is modeled by using three different ANN structure and the most successful network structure is determined related to this modeling. The Neural Networks models used in this thermal modeling analysis are; i- Feed-forward Neural Networks, ii-Elman Recurrent Neural Networks and iii- Nonlinear autoregressive with exogenous inputs (NARX). In addition, Levenberg-Marquardt and Bayesian Regularization teaching algorithms are applied to the three ANN models and the results are compared. The same training algorithm and network structure are applied on two different experiment test data obtained from 3 kVA and 5kVA dry type transformers. The network structure and training algorithms are evaluated by using performance determinant factor. By comparing the results, it is determined that Bayesian regularization is the best training algorithm and NARX recurrent model is the best network structure in thermal analysis of dry type transformer windings.

Keywords: Dry type transformer, artificial neural network, dynamic modeling, recurrent

1.GİRİŞ (INTRODUCTION)

Birkaç vatlık transformatörlerden en büyük güç transformatörlerine kadar işletme sırasında karşılaşılan en büyük sorun çekirdek ve sargılarda

oluşan kayıplardan dolayı meydana gelen ısınmadır. Isınmanın kullanılan yalıtkan malzemesi üzerine etkisi, transformatörün ömrünü belirleyeceğinden,

izolasyon malzemelerinin iyi seçilmesi gerekir. Bu nedenle çeşitli güçlerde ve soğutma düzenlerindeki transformatörler için belirlenmiş olan sınır ısınmayı sağlayan yalıtkan sınıfları çeşitli şartnamelerden saptanır [1]. Transformatör yüklenirken bu yalıtkan sınıfının dayanabileceği sınır sıcaklıklar göz önüne alınmalıdır [2].

Standart sınıftaki kuru tip transformatörler için verilen standart ortalama sıcaklık artışı 80, 115 ve 150 dereceyken en sıcak nokta sıcaklığı sırasıyla maksimum 150, 185 ve 220°C dir [3]. Transformatörlerin çeşitli çalışma sıcaklıklarında muhtemel ömrü tam olarak bilinmemektedir. İzolasyon ömrü üzerinde çalışma sıcaklığının etkilerini hesaplarken, aşırı yüklenmeler veya yüksek ortam sıcaklığından dolayı oluşan normal çalışma sıcaklığından daha yüksek sıcaklıklar transformatörün izolasyonuna zarar verir ve dolayısıyla transformatörün ömrünü azalttığı konusunda görüş birliği vardır [4]. Bu nedenle transformatör sargılarının normal çalışma koşulları altında sargı ısınmasının sargı yüksekliği boyunca eşit olmamasından dolayı, en sıcak-nokta sıcaklığının bilinmesi büyük önem taşır. Bu ısınmayı tespit etmek, ancak sargı yüksekliği boyunca detaylı termal analiz yapmakla mümkündür. Böylece transformatör sargısının en sıcak-nokta yeri tespit edilebilirse transformatörün aşırı yüklenme süreleri ve sınırları artırılabilir [6].

Literatürde, transformatör sıcaklığı gibi doğrusal olmayan karakteristiklere sahip ve önceden tahmini mümkün olmayan durumlar içeren sistemlerin tanımlanmasında akıllı hesaplama yöntemleri kullanan birçok çalışma mevcuttur. Bu yöntemlerle transformatör modeline ve uzman bilgisine daha az ihtiyaç duyulur. YSA'nın kullanılmasındaki amaç kompleks ve lineer olmayan yapılarda öğrenebilme yeteneğidir. Hem modelleme de daha hızlı ve herhangi bir algoritmayı model üzerinde kullanmada daha fazla kolaylık sağlar. ANSI/IEEE [4] matematiksel teknikleri kullanıldığı zaman kesin ve mevcut olmayan transformatör parametrelerine ihtiyaç duyulur. Klasik yöntemlerle modelleme yapıldığında büyük miktarlarda matematiksel denklemlerle uğraşmak zorunda kalınır. Klasik algoritmalarda tam olarak tanımlı bir çözüm yolu olmayan problemler çözülemezken YSA sayesinde problemler çözüm yöntemi hakkında herhangi bir bilgi verilmeksizin çözülebilir. YSA'nın bu tip problemleri çözebilmesi için gereken tek şey örnek girdiler için sonuçların verilmesidir.

Literatürdeki çalışmalar genellikle yağlı tip transformatörler üzerine yapılmıştır [6-10]. He [6] yağ sıcaklığının tahmin edilmesinde 4 farklı YSA modeli kullanılmıştır. Bunlar statik ağlar (Feedforward Neural networks), Gecikmeli zaman odaklı ağlar (Focused Time Delay Neural Networks), Geri

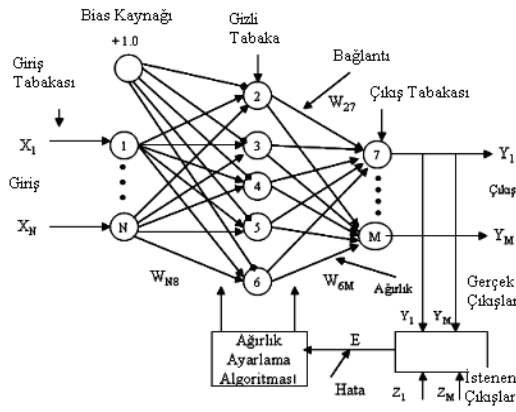
beslemeli ağlar (Recurrent Neural Networks) ve lineer ARX (Linear Auto Regression Models) modelidir. En iyi performansın Levenberg-Marquardt öğrenme algoritması kullanan geri beslemeli YSA (RNN) 'dan elde edildiği belirtilmiştir [6]. Nguyen [7] ise çok katmanlı statik ağ yapısı ve geri beslemeli yapay sinir ağları üzerinde çalışmış ve He'nin çalışmasında elde ettiği sonuçları kanıtlamıştır. Bu çalışmada son zamanlarda güvenlik ve bakım avantajlarından dolayı yağlı tip transformatörlerden daha fazla tercih edilen kuru tip transformatörlerin sargı sıcaklığını tahmin etmek için kullanılacak YSA modeli ve eğitim algoritmalarından hangisinin daha iyi sonuç vereceği araştırmasına gidilmiştir. Laboratuvar ortamında 3 kVA 'lık ve 5 kVA'lık iki kuru tip transformatör için iki ayrı deney düzeneği kurulup iki ayrı zaman diliminde sistemden veriler alınmıştır. YSA için giriş verileri olarak yük akımı, ortam sıcaklığı ve giriş gerilimi, çıkış verisi olarak da sargı sıcaklığı düşünülmüştür. Diğer çalışmalarda kullanılan Levenberg-Marquardt algoritmasının yanı sıra Bayesian Regulation öğrenme algoritması kullanılmıştır. İki algoritmanın kıyaslanmasında Bayesian regulation algoritmasının daha iyi sonuç verdiği performans belirleyiciden görülmüştür. YSA modeli olarak statik ağ (İleri beslemeli), Elman geri besleme (ERNN) ve NARX (Nonlinear Auto Regression Model) geri besleme modelleri kullanılmıştır. NARX, geri besleme modelinin hem daha hızlı ve hem de daha iyi performans sağladığı performans belirleyiciden saptanmıştır. 3kVA'lık ve 5kVA'lık transformatörden alınan iki ayrı deney veri seti için aynı öğrenme algoritması ve aynı ağ yapıları uygulanmıştır. Sonuçlar kıyaslandığında değişimlere karşı verdikleri sistem tepkilerinin ikisinin de aynı olduğu gözlemlenmiştir.

2. YAPAY SİNİR AĞ MODELLERİ (ARTIFICIAL NEURAL NETWORK MODELS)

Sinir ağlarındaki işaretin akış yönüne bağlı olarak, ileri beslemeli (feedforward) ve geri beslemeli (feedback veya recurrent) ağlar olmak üzere iki çeşittir.

2.1. İleri beslemeli ağlar (Feedforward Networks)

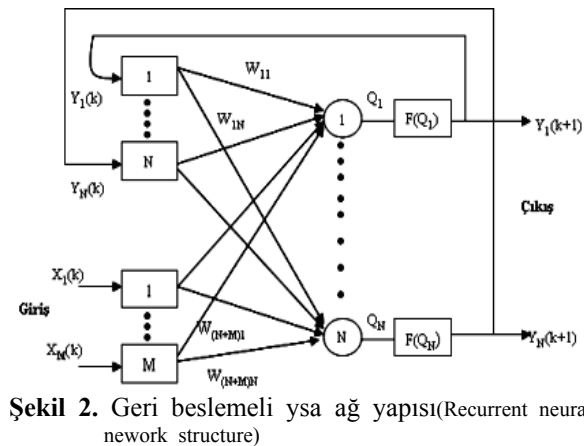
İleri beslemeli ağlar yapay sinir ağlarının en basit ve en ilkel yapısıdır. Bu ağda bilgi sadece ileri yönde gizli ve çıkış katmanına doğru hareket eder. Sistem belleksizdir. Bu yapay sinir ağ yapısına statik ağlarda denilmektedir [7]. Şekil 1'de çok katmanlı ileri beslemeli ağ yapısını görülmektedir. Şekilde görüldüğü üzere sinyaller daima ileri yöne taşınmaktadır. İleri beslemeli bağlantıların ağırlıkları eğitim sırasında değiştirilebilir ama geri dönüşümlerin bağlantı ağırlıkları değiştirilemez, sabittirler.



Şekil 1. İleri beslemeli YSA ağ yapısı (Feedforward neural networks structure)

2.2. Geri Beslemeli Ağlar (Recurrent Networks)

Gerçek beslemeli sinir ağı çıkış ve ara katlardaki çıkışlardan giriş birimlerine veya önceki ara katmanlara geri beslenmenin yapıldığı bir ağ yapısıdır. Bu çeşit sinir ağlarının dinamik hafızaları vardır. Bu yapıdaki nöronların çıkışı sadece o anki giriş değerlerine bağlı değildir ayrıca önceki giriş değerlerine de bağlıdır. Bundan dolayı, bu ağ yapısı özellikle tahmin uygulamaları için uygundur. Bu ağlar özellikle çeşitli tipteki zaman serilerinin tahmininde oldukça başarı sağlamıştır [11].




Şekil 2. Geri beslemeli ysa ağ yapısı (Recurrent neural network structure)

Şekil 2’de toplam N tane çıkış nöronu mevcuttur ve M tane dış giriş elemanından oluşur. Çıkışlar, giriş elemanymış gibi birim zaman gecikmesiyle geri beslenirler. Böylece toplam (M+N) giriş olmuş olur. $X(k)$ ağa uygulanan dış giriş vektörünü temsil eder ve $Y(k+1)$ ise $(k+1)$ ayrık zamanda bir step sonra üretilen nöron çıkış vektörünü temsil eder. Giriş vektörü $X(k)$ ve bir step gecikmeli çıkış vektörü $Y(k)$ ’ yı içeren toplam giriş vektörü [12];

$$\begin{pmatrix} Q_1 \\ \vdots \\ Q_N \end{pmatrix} = \begin{pmatrix} W_{11} & \dots & W_{(N+M)1} \\ \vdots & \ddots & \vdots \\ W_{1N} & \dots & W_{(N+M)N} \end{pmatrix} \begin{pmatrix} U_1 \\ \vdots \\ U_N \end{pmatrix} \quad (1)$$

Gelecek adım olarak, j. çıkış nöronu aktivasyon fonksiyonu $F()$ den geçirilerek aşağıdaki eşitlik bulunur.

$$Y_j(k+1) = F(Q_j(k)) \quad (2)$$



Şekil 3. NARX ysa modeline ait ağ yapısı (NARX neural network structure)

3. YAPAY SİNİR AĞ MODELLERİNİN EĞİTİMİ (TRAINING OF NEURAL NETWORK MODELS)

Yapay sinir ağlarında eğitim genellikle bir optimizasyon problemi olarak görülür. Özellikle yapay sinir ağlarında eğitimin amacı, ağdaki ağırlıkları ayarlayarak hata değerini minimize etmektir. Bir karesel hata fonksiyonunun toplamı (mean square error - mse) Eşitlik 3’i kullanılarak hesaplanılır.

$$E(w) = \frac{1}{n} \sum_{\xi,i} (e_i^\xi)^2 = \frac{1}{n} \sum_{\xi,i} (d_i^\xi - y_i^\xi)^2 \quad (3)$$

d_i^ξ hedef edilen çıkış değeri ve y_i^ξ ağıın çıkışından elde edilen değerdir. Her ağırlık Eşitlik 4 ile ayarlanır:

$$w^{(k+1)} = w^{(k)} + \Delta w^{(k)} \quad (4)$$

$E(w)$ ’yi mümkün olduğu kadar hızlı bir şekilde azaltmak için $\Delta w^{(k)}$ ayarlanır. $\Delta w^{(k)}$ ’nın hesaplanması kullanılacak eğitim algoritmasına göre değişir. Uygulamalarda en yaygın ve çok kullanılmış olan geri yayımlı (back propagation) algoritmasıdır. Geri

yayılmı ağında hatalar, ileri besleme aktarma işlevinin türevi tarafından, ileri besleme mekanizması içinde kullanılan bağlantılar aracılığıyla geriye doğru yayılmaktadır [18]. Standart BP algoritmasında uzun hesaplama zamanı ve yerel minimumda yakınsama riski gibi dezavantajları vardır [12-18]. Farklı optimizasyon tekniklerini kullanarak performansı geliştiren yüksek performanslı BP eğitim algoritmalarından ikisi üzerinde bu makalede çalışılmıştır. Bu algoritmalar Levenberg-Marquardt [15, 16, 19] ve Bayesian [11, 20] Regulation algoritmalarıdır. Bunlar kısaca aşağıda özetlenilmiştir:

Levenberg-Marquardt (LM) Method: Levenberg-Marquardt temel olarak maksimum komşuluk üzerine kurulmuş en az kareler hesaplama metodudur. Bu algoritma Gauss-Newton ve gradient-descent algoritmalarının en iyi özelliklerinden oluşur ve bu iki metodun kısıtlamalarını kaldırır. Genel olarak bu metod yavaş yakınsama probleminden etkilenmez. Gauss-Newton algoritmasının kombinasyonu olan Levenberg-Marquardt algoritması optimizasyon problemlerinde eğimli düşüş algoritmasına göre (gradient descent) daha etkindir. Ayrıca daha hızlıdır.

Bayesian Regulation Method: Bayesian regülasyonu Levenberg Marquardt optimizasyonuna göre ağırlık ve bias değerlerini günceller. Karesele hata ve ağırlıkların kombinasyonu minimize eder ve ağı üretmek için doğru kombinasyonu belirler. Daha iyi genelleştirme yeteneğine sahip bir ağı oluşturmak için Mackay [11] regülasyonu ağı parametrelerinin boyutunu sınırlayan yöntem önermiştir. Regülasyon teknikleri ağırlık değerlerinin daha küçük değerlerde kalması için ağı zorlar. Bu ağı cevabının daha yumuşak olmasına, ağı ezberleme (over fitting) olasılığının azalmasına ve gürültüyü yakalamasına neden olur.

4. BİR YAPAY SİNİR AĞININ TASARIMI (PLANNING OF AN ARTIFICIAL NEURAL NETWORK)

Bir sinir ağı modeli oluşturmak için nöronların bağlantı şekli, işlemci elemanlarının kullandıkları toplama ve aktivasyon fonksiyonları, öğrenme metodu, öğrenme kuralı ve algoritması belirlenmelidir. Eldeki veriye göre model tasarlanır. Kurulan modelin başarısı modelin mimarisinin doğru oluşturulması ile doğrudan ilgilidir. Bunun için yapay sinir ağı tasarımcısının, ağı yapısına ve işleyişine ilişkin aşağıdaki kararları vermesi gerekmektedir.

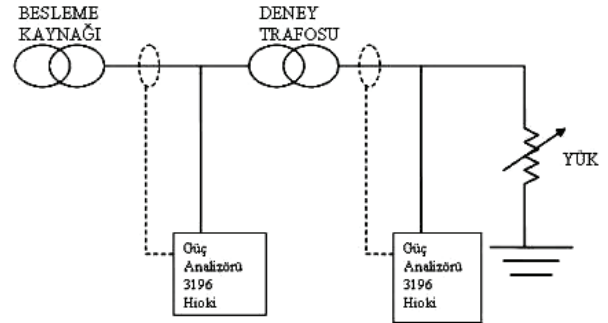
- Ağı mimarisinin seçimi ve yapısal özelliklerinin belirlenmesi (katman sayısı ve katmandaki nöron sayısı)
- İşlemci elemanların kullandığı fonksiyonların karakteristik özelliklerinin belirlenmesi

- Öğrenme algoritması ve parametrelerin belirlenmesi
- Eğitim ve test setinin oluşturulması

Bu kararlar doğru verilmediği takdirde sistem karmaşıklığı artacaktır. En doğru kararı verebilmek için literatürdeki benzer çalışmalar gözden geçirilerek uygulanacak problem için belirlenmiş olan parametrelerle yapıyı tasarlamaya ve eğitmeye başlamak en akılcı yaklaşım olacaktır. Ayrıca sistem tasarlanırken uygulamanın ne kadar süreceği, hafızada ne kadar yer kaplayacağı gibi bilgiler düşünülmelidir.

5. UYGULAMALAR VE DEĞERLENDİRME (APPLICATIONS AND EVALUATION)

Düşünülen yapay sinir ağı modellerinin modellenmesi için Matlab 2010b paket programı kullanılmıştır. Sıcaklık sensörü olarak dört telli PT100 tercih edilmiştir. Sensörlerden veriler LR8400 Hoki Dataloggeri ile kaydedilmiştir. Laboratuvardaki omik yük bankları kullanarak transformatörün yüklenmesi sağlanmıştır. Güç analizörü olarak Hioki markasının 3196 serisi kullanılmıştır. Şekil 4'te deneyin elektriksel devre şeması görülmektedir [5].




Şekil 4. Deneyin elektriksel bağlantı şeması (The electrical scheme of experiment)

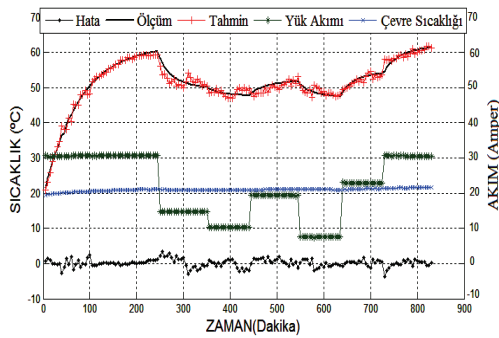
Yapay sinir ağı modellemesinde ağı giriş verisi olarak yük akımı, giriş gerilimi ve çevre sıcaklığı; çıkış verisi olarak da sargı sıcaklığı sunulmuştur. Bütün veriler ağı sunulmadan önce (-1,+1) arasında normalizasyon işlemine tabi tutulmuştur. Ara katmanlarda aktivasyon fonksiyonu olarak logsig; çıkış katmanında doğrusal (purelin) kullanılmıştır. Matlab programı kullanılarak eğitim parametrelerinden öğrenme oranı 0,2 ile 0,8 ve iterasyon sayısı 100 ile 1000 arasında değiştirilmiştir. Doğru ağı yapısını bulabilmek için farklı gizli katmandaki nöron sayısı ve gecikme sayısı değerlendirilmiştir. Tamamı dikkate alınarak yapılan çalışmalarda elde edilen minimum hata değerleri (RMSE) çizelgelerde sunulmuştur. Öğrenme oranı 0,4 kabul edilmiş; iterasyon sayısı ileri beslemeli ve Elman geri beslemeli yapay sinir ağı modeli için 200, NARX geri beslemeli model için ise 1000 seçilmiştir.

5.1. 5 kVA 'lık Transformatör için Uygulama (Application for 5 kVA transformer)

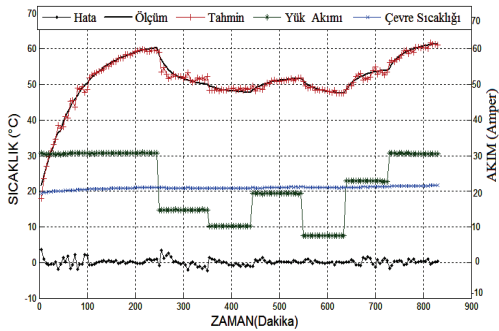
Transformatörün sargı sıcaklığını ölçmek için sargıların içinde belirlenen 5 noktaya 5 adet sıcaklık sensörü yerleştirilip 5 adet ölçümün ortalaması alınarak elde edilen sonuç, transformatörün sargı sıcaklığı olarak kabul edilmiştir. Transformatörün çevresindeki üç noktadan çevre sıcaklığı ölçülüp ortalaması alınarak çevre sıcaklığı elde edilmiştir [5]. 5'er dakika aralıklarla deneyden ölçüm verileri alınmıştır. Toplam 333 veri elde edilmiştir. 167 veri yapay sinir ağ yapısında eğitim amaçlı geriye kalan 166 veri de test amaçlı kullanılmıştır.



Şekil 5. YSA'nın girişine uygulanan şebeke geriliminin değişimi (Changing of line voltage applied to NN)



Şekil 6. $\mu=0,4$ ve $n_h=11$ olan ileri beslemeli YSA'nın LM eğitim algoritmasını kullanarak simülasyonu (Simulation of feedforward NN for $\mu=0.4$ and $n_h=11$ by using LM algorithm)

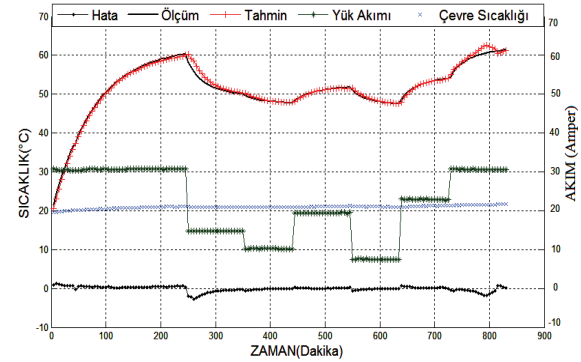


Şekil 7. $\mu=0,4$ ve $n_h=11$ olan ileri beslemeli YSA'nın BR algoritmasını kullanarak simülasyonu (Simulation of feedforward NN for $\mu=0.4$ and $n_h=11$ by using BR algorithm)


Şekil 6 ve Şekil 7' de deney sonucunda ölçülen sargı sıcaklığı (Ölçüm), yük akımı (Amper), çevre sıcaklığı verileri, ileri beslemeli YSA modelinden geçtikten sonra tahmin edilen sargı sıcaklığı, ölçülen sargı sıcaklığı ile tahmin edilen sargı sıcaklığı arasındaki fark (hata) gösterilmiştir. Şekil 5, Şekil 6 ve Şekil 7 ile karşılaştırıldığında transformatörün sargı sıcaklığının üzerinde yük akımının büyük etkisi olduğu görülmektedir.

Tablo 1. İleri beslemeli YSA modelinin farklı n_h ve eğitim algoritmalarına göre performans değişimi (Performance changing result of feedforward NN according to different n_h and training algorithms (5KVA))

Eğitim Algoritması	n_h	RMSE	Min	Max
Levenberg-Marquardt	9	1,0929	-3,2171	3,5041
	10	1,0105	-3,3535	2,9648
	11	0,9470	-2,5468	4,2540
	12	1,0179	-2,3890	5,1182
Bayesian Regulation	9	0,9052	-2,0972	3,3621
	10	0,8943	-2,1436	3,4596
	11	0,8964	-2,0419	3,5145
	12	0,8945	-2,1032	3,4820



Şekil 8. $\mu=0,4$ ve $n_h=12$ olan Elman geri beslemeli YSA'nın LM eğitim algoritmasını kullanarak simülasyonu (Simulation of Elman recurrent NN for $\mu=0.4$ and $n_h=11$ by using LM algorithm)



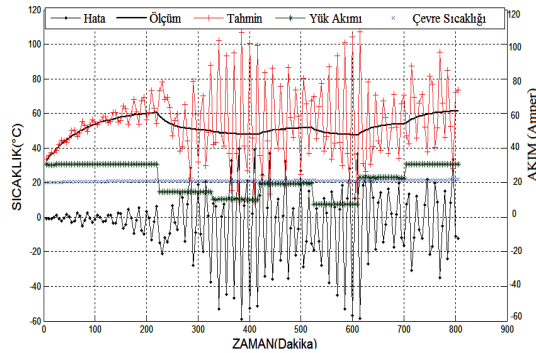
Şekil 9. $\mu=0,4$ ve $n_h=12$ olan Elman geri beslemeli YSA'nın BR algoritmasını kullanarak simülasyonu (Simulation of Elman recurrent NN for $\mu=0.4$ and $n_h=11$ by using BR algorithm)

Tablo 1 incelendiği zaman ileri beslemeli YSA modelinde en iyi performansın BR eğitim algoritmasında gizli katmanda $n_h=12$ nöron sayısı ile elde edildiği görülmüştür.

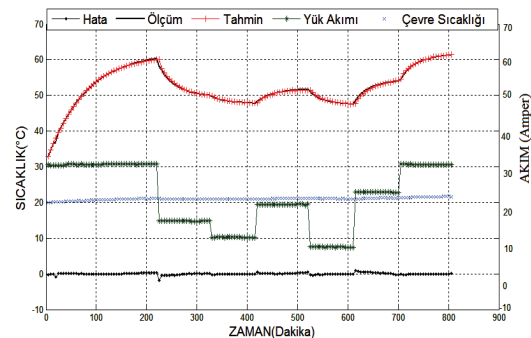
Tablo 2. Elman geri beslemeli YSA modelinin farklı n_h ve eğitim algoritmalarına göre performans değişimi (Performance changing result of Elman recurrent NN according to different n_h and training algorithms) (5KVA)

Eğitim Alg.	n_h	RMSE	Min	Max
Levenberg-	9	0,4938	-2,1997	1,1324
	10	0,4545	-1,5210	1,4802
Marquardt	11	0,3785	-1,7922	1,275
	12	0,3620	-1,4373	1,2133
Bayesian Regulation	9	0,3504	-1,3397	1,2254
	10	0,3503	-1,3544	1,2414
	11	0,3346	-1,3544	1,2357
	12	0,3311	-1,3509	1,2102

Tablo 2 incelendiği zaman Elman geri beslemeli YSA modelinde en iyi performansın Bayesian regulation eğitim algoritmasında gizli katmanda $n_h=12$ nöron sayısı ile elde edildiği görülmüştür.



Şekil 10. $\mu=0,4$ ve $n_h=12$ olan NARX geri beslemeli YSA'nın LM eğitim algoritmasını kullanarak simülasyonu (Simulation of NARX recurrent NN for $\mu=0.4$ and $n_h=11$ by using LM algorithm)



Şekil 11. $\mu=0,4$ ve $n_h=12$ olan NARX geri beslemeli YSA'nın BR algoritmasını kullanarak simülasyonu (Simulation of NARX recurrent NN for $\mu=0.4$ and $n_h=11$ by using BR algorithm)

Şekil 10 ve Şekil 11'de NARX geri beslemeli YSA modelini kullanarak iki farklı eğitim algoritmasına ait benzetim sonuçları sunulmuştur. LM eğitim algoritması uygulanarak tahmin edilen sargı sıcaklığı

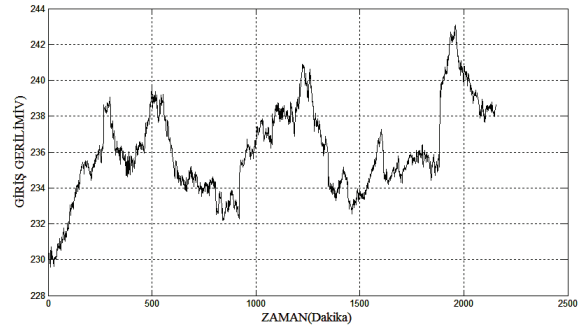
ile ölçülen sargı sıcaklığı arasında büyük farklar oluşmuştur. Deneme yöntemiyle performans belirleyicinden elde edilen değerler 30' un üzerinde olduğu için NARX yapısında LM eğitimi sonucunda elde edilen tahmin değerleri sunulmamıştır.

Tablo 3. BR eğitim algoritmasını kullanarak $\mu=0,4$ olan geri beslemeli NARX ağ modelinin farklı n_h sayılarına göre performans değişiminin sonuçları (Performance changing result of NARX recurrent NN according to different n_h and training algorithms for $\mu=0.4$) (5KVA)

Eğitim Alg.	n_h	Gecikme Say.	RMSE	Min	Max
BR	10	2	0,3240	-1,7276	1,1023
		3	0,3099	-1,8514	1,2779
		4	0,3129	-1,8201	1,3465
	12	5	0,3202	-1,8377	1,5307
		2	0,2974	-1,7634	0,9952
		3	0,2819	-1,8874	1,0192

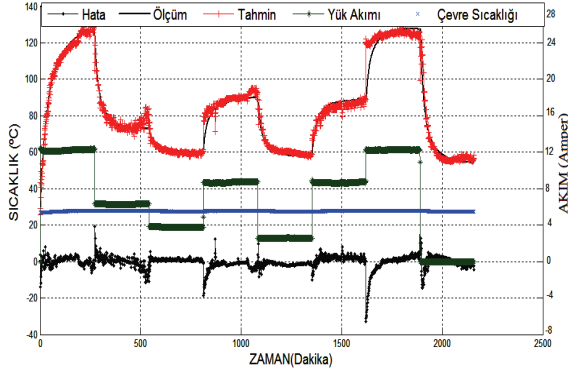
5.2. 3KVA 'lık Transformör için Uygulama (Application for 3KVA transformer)

Transformörün sargı sıcaklığını ölçmek için sargıların içinde belirlenen 18 noktaya 18 adet PT100 sıcaklık sensörü yerleştirilip 18 adet ölçümün ortalaması alınarak elde edilen sonuç transformörün sargı sıcaklığı olarak kabul edilmiştir. Transformörün çevresindeki üç noktadan çevre sıcaklığı ölçülüp ortalaması alınarak çevre sıcaklığı elde edilmiştir [5]. 1'er dakika aralıklarla deneyden ölçüm verileri alınmıştır. Toplam 4318 veri elde edilmiştir. 2159 veri yapay sinir ağ yapısında eğitim amaçlı geriye kalan 2159 veri de test amaçlı kullanılmıştır.

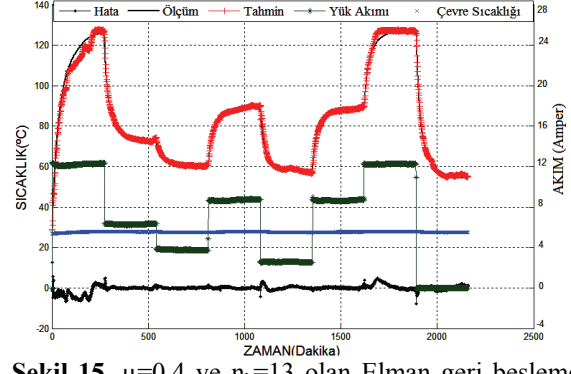


Şekil 12. YSA'nın girişine uygulanan şebeke geriliminin değişimi (Changing of line voltage applied to NN)

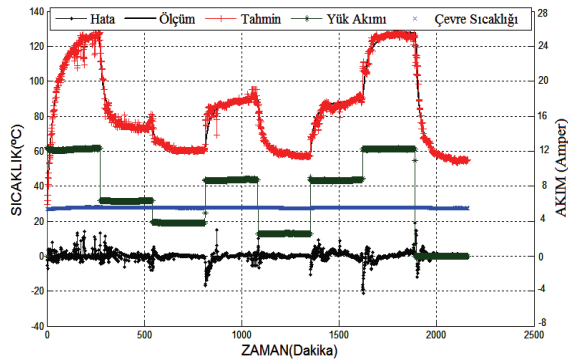
Şekil 13 ve Şekil 14' de deney sonucunda ölçülen sargı sıcaklığı (ölçüm), yük akımı (Amper), çevre sıcaklığı verileri, ileri beslemeli YSA modelinden geçtikten sonra tahmin edilen sargı sıcaklığı, ölçülen sargı sıcaklığı ile tahmin edilen sargı sıcaklığı arasındaki fark (hata) gösterilmiştir. Şekil 12, Şekil 13 ve Şekil 14 ile karşılaştırıldığında transformörün sargı sıcaklığının üzerinde yük akımının büyük etkisi olduğu görülmektedir.



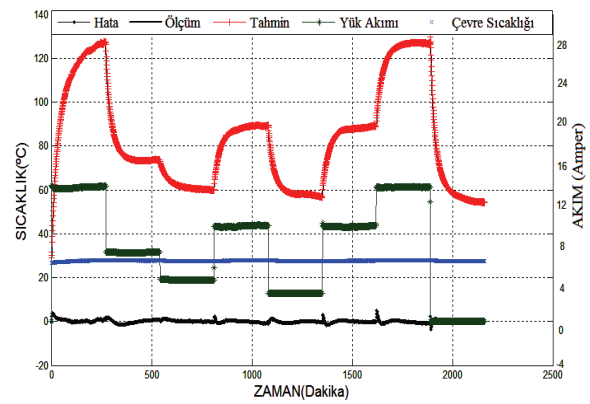
Şekil 13. $\mu=0,4$ ve $n_h=11$ olan ileri beslemeli YSA'nın LM eğitim algoritmasını kullanarak simülasyonu (Simulation of feedforward NN for $\mu=0.4$ and $n_h=11$ by using LM)



Şekil 15. $\mu=0,4$ ve $n_h=13$ olan Elman geri beslemeli YSA'nın LM eğitim algoritmasını kullanarak simülasyonu (Simulation of Elman recurrent NN for $\mu=0.4$ and $n_h=11$ by using LM algorithm)



Şekil 14. $\mu=0,4$ ve $n_h=11$ olan ileri beslemeli YSA'nın BR algoritmasını kullanarak simülasyonu (Simulation of feedforward NN for $\mu=0.4$ and $n_h=11$ by using BR algorithm)



Şekil 16. $\mu=0,4$ ve $n_h=13$ olan Elman geri beslemeli YSA'nın BR algoritmasını kullanarak simülasyonu (Simulation of Elman recurrent NN for $\mu=0.4$ and $n_h=11$ by using BR algorithm)

Tablo 4. İleri beslemeli YSA modelinin farklı n_h ve eğitim algoritmalarına göre performans değişimi (Performance changing result of feedforward NN according to different n_h and training algorithms) (3KVA)

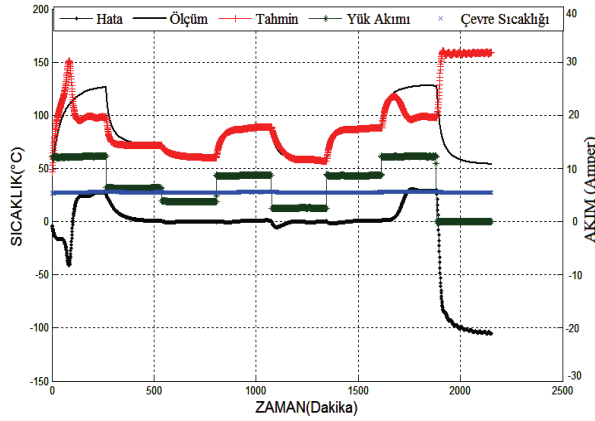
Eğitim Alg.	n_h	RMSE	Min	Max.
Levenberg-Marquardt	9	3,4514	-29,0323	20,3963
	10	3,6734	-30,4471	23,7401
	11	2,8169	-24,1933	20,3604
Bayesian Regulation	12	3,6860	-29,1660	20,8391
	9	2,7323	-21,6453	16,9064
	10	2,8638	-22,9138	16,1885
Bayesian Regulation	11	2,5817	-21,8969	19,6487
	12	2,9418	-53,8922	48,3792

Tablo 4 incelendiği zaman ileri beslemeli YSA modelinde en iyi performansın Bayesian regulation eğitim algoritmasında gizli katmanda $n_h=11$ nöron sayısı ile elde edildiği görülmüştür.

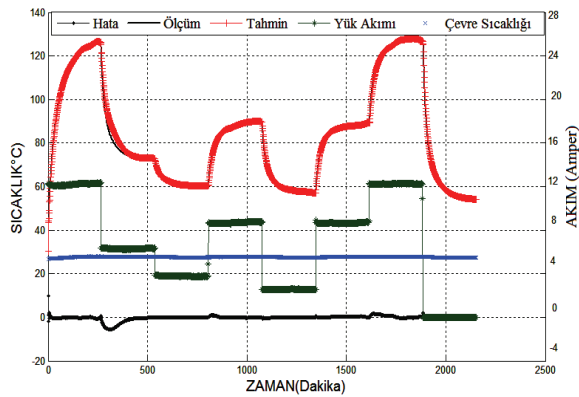
Tablo 5. Elman geri beslemeli YSA modelinin farklı n_h ve eğitim algoritmalarına göre performans değişimi (Performance changing result of Elman recurrent NN according to different n_h and training algorithms) (3KVA)

Eğitim Alg.	n_h	RMSE	Min	Max.
Levenberg-Marquardt	10	1,5157	-7,5032	18,2856
	11	1,4894	-5,4145	8,4288
	12	1,1819	-2,4420	8,6926
Bayesian Regulation	13	0,7880	-5,8666	3,5396
	10	1,2692	-7,5326	12,1822
	11	1,2246	-7,9201	15,6288
Bayesian Regulation	12	0,9827	-3,2562	16,0129
	13	0,6326	-2,0335	12,3922

Tablo 5 incelendiği zaman Elman geri beslemeli YSA modelinde en iyi performansın Bayesian regulation eğitim algoritmasında gizli katmanda $n_h=13$ nöron sayısı ile elde edildiği görülmüştür.



Şekil 17. $\mu=0,4$ ve $n_h=12$ olan NARX geri beslemeli YSA'nın LM eğitim algoritmasını kullanarak simülasyonu (Simulation of NARX recurrent NN for $\mu=0.4$ and $n_h=11$ by using LM algorithm)



Şekil 18. $\mu=0,4$ ve $n_h=12$ olan NARX geri beslemeli YSA'nın BR eğitim algoritmasını kullanarak simülasyonu (Simulation of NARX recurrent NN for $\mu=0.4$ and $n_h=11$ by using BR algorithm)

Şekil 17 ve Şekil 18'de NARX geri beslemeli YSA modelini kullanarak iki farklı eğitim algoritmasına ait simülasyon sonuçları sunulmuştur. Şekil 17' de Levenberg-Marquardt eğitim algoritması uygulanarak tahmin edilen sargı sıcaklığı ile ölçülen sargı sıcaklığı arasında büyük farklar oluşmuştur. Deneme yöntemiyle performans belirleyiciden elde edilen değerler yirminin üzerinde olduğu için NARX yapısında Levenberg-Marquardt eğitimi sonucunda elde edilen tahmin değerleri sunulmamıştır.

Tablo 6. $\mu=0,4$ olan geri beslemeli NARX ağ modelinin farklı n_h sayılarına göre performans değişiminin sonuçları (Performance changing result of NARX recurrent NN according to different n_h and training algorithms for $\mu=0.4$) (3KVA)

Eğitim Alg.	n_h	Gecikme Say.	RMSE	Min	Max
BR	10	5	2,4946	-3,8709	10,948
		6	1,5955	-6,7888	3,9145
		7	2,0444	-12,943	4,5348
	12	5	1,5601	-4,9792	10,817
		6	0,6248	-2,8375	7,9477
		7	0,7869	-5,3460	1,9462

6.SONUÇ (CONCLUSION)

Bu çalışmada son zamanlarda güvenlik ve bakım avantajlarından dolayı yağlı tip transformatörlerden daha fazla tercih edilen kuru tip transformatörlerin sargı sıcaklığını tahmin etmek için kullanılacak YSA modeli ve eğitim algoritmalarından hangisinin daha iyi sonuç vereceği araştırmasına gidilmiştir. Laboratuvar ortamında 3 kVA 'lık ve 5 kVA'lık kuru iki transformatör için iki ayrı devre düzeneği kurulup iki ayrı zaman diliminde sistemden veriler alınmıştır. YSA için giriş verileri olarak yük akımı, ortam sıcaklığı ve giriş gerilimi; çıkış verisi olarak da sargı sıcaklığı düşünülmüştür. YSA modeli olarak statik ağ (İleri beslemeli), Elman geri besleme (ERNN) ve NARX (Nonlinear Autoregression Model) geri besleme modelleri kullanılmıştır. Matlab 2010b paket programı vasıtasıyla YSA modelinin benzetimleri yapılmıştır. 3 modelin karşılaştırılması yapıldığında NARX geri besleme ağ modelinin hem daha hızlı ve hem de daha iyi performans sağladığı performans belirleyicilerden görülmüştür. 3kVA 'lık ve 5 kVA'lık transformatörden alınan iki ayrı veri seti için aynı öğrenme algoritması ve aynı ağ yapıları uygulanmıştır. Sonuçlar kıyaslandığında verdikleri sistem tepkileri ikisinin de aynıdır. Ayrıca Levenberg-Marquardt ve Bayesian Regulation eğitim algoritmaları karşılaştırılması sonucunda daha iyi genelleştirme yeteneğine sahip olan Bayesian algoritmasının daha iyi sonuç verdiği elde edilen benzetim sonuçlarında görülmüştür.

SEMBOLLER (SYMBOLS)

- $E(w)$:Mean square error(karesel ortalama hata)
 RMSE :Root mean square error
 Δw^k :YSA' daki ağırlık değişiminin farkı
 n_h :Gizli katmandaki nöron sayısı
 LM :Levenberg-Marquardt
 BR :Bayesian Regulation
 μ :Öğrenme oranı
 z^{-1} :Birim gecikme
 n :Yapay sinir ağlarında toplam örnek sayısı

KAYNAKLAR (REFERENCES)

- “Güç Transformatörleri Sıcaklık Artışı”,TSE Standart TS 10901 EN 60076-2, 1998.
- Kömürgöz G., Güzelbeyoğlu N., ” Kendi kendine soğuyan kuru tip güç transformatörlerinde sıcaklık dağılımının belirlenmesi”, **itüdergisi/d mühendislik**, 1:1 (2002).
- “IEEE Recommended Practice for Installation, Application, Operation, and Maintenance of Dry-Type General Purpose Distribution and Power Transformers”, **IEEE Standard ANSI/IEEE C57.94-1982**, DOI: 10.1109/IEEESTD.1982.106993.

4. "IEEE Guide for Loading Dry-Type Distribution and Power Transformers", **IEEE Standard ANSI/IEEE C57.96-1999**, DOI: 10.1109/IEEESTD.1999.90581
5. Iskender I., Mamizadeh A., "Thermal Capacitance Calculation of Top-Oil Temperature for Power Transformers", **International Review Of Electrical Engineering**, vol. 4 Issue:5 Part: A pp. 882-886(2009)
6. He, Q. , Si, J. and Tylavsky, D. , "Prediction of top-oil temperature for transformers using neural network", **IEEE Transactions on Power Delivery** , 1205-1211(2000).
7. Nguyen, H.H. ," A neural fuzzy approach to modeling the thermal behaviour of power transformers", Yüksek Lisans Tezi, **School of Electrical Engineering Faculty of Health, Engineering&Science Victory University**, 17-24(2007).
8. Galdi, V. , Ippolito, L. ,Piccola, A., "Neural Diagnostic System for Transformer Thermal Overload Protection", **IEE Proc-Electr. Power Appl.**, Vol:147, No:5, 415-417(2000).
9. Tylavsky, D. , He, Q. , and Si, J. , "Transformer Top-oil Temperature Modeling and Simulation", **IEEE Transactions on Industry Appl.**, 1219-1225(2000).
10. Assunção, T. , Silvino, J. and Resende, P. , "Transformer Top-oil Temperature Modeling and Simulation", **Proceedings of World of Science Engineering and Techology**, Vol:15,240-245(2006)
11. Mackay, D.J.C. , "Bayesian interpolation," **Neural Computation**, vol. 4, pp. 415-447, 1992.
12. Bose, B. , "Neural Network Principles and Applications", **Prentice Hall PTR**, United States of America, 625-657(2002).
13. Hagan, M.T., Demuth, H.B., Beale, M., "Neural Network Design", Boston, **PWS Publishing Company**, 1995.
14. Maren, A., Harston, C., Pap, R., "Handbook of Neural Computing Applications", **New York, Academic Press**, 1990.
15. Vas, P., "Artificial Intelligence Based Electrical Machines and Drivers", New York, **Oxford University Press**, 1999.
16. Hagan, M.T., Menhaj, M., "Training feedforward networks with the marquardt algorithm", **IEEE Neural Networks**, Vol. 5(6), pp. 989-993, 1994.
17. Ham, F.M., Kostanic, I., "Principles of Neurocomputing for Science and Engineering", New York, **Mc-Graw Hill**, 2001.
18. Rojas, R., "Neural Networks A Systematic Introduction", New York, **Springer Verlag**, 1996.
19. Foo, J.S., Ghosh, P.S., "Artificial Neural Network Modelling of Partial Discharge Parameters For Transformer Oil Diagnosis", **Annual Report Conference on Electrical Insulation and Dielectric Phenomena**, Malaysia, pp. 470-473, 2002.
20. Foresee, F.D., Hagan, M.T., "Gauss-Newton approximation to Bayesian regularization", **Proc. of Int. Conference on Neural Networks ICNN'97**, pp.1930-1935, 1999.

