

## DENEYSEL BİR ORGANİK RANKİNE ÇEVİRİMİNDE YAPAY SİNİR AĞLARI (YSA) YARDIMIYLA GÜÇ TAHMİNİ

<sup>1</sup>Hasan Hüseyin BİLGİÇ, <sup>2</sup>Hüseyin YAĞLI, <sup>3</sup>Ali KOÇ, <sup>4</sup>Ahmet YAPICI

<sup>1,2,3,4</sup>İskenderun Teknik Üniversitesi, Makine Fakültesi, Makine Mühendisliği Bölümü, İskenderun, HATAY  
<sup>1</sup>bilgichh@gmail.com, <sup>2</sup>hsyn.yagli@gmail.com, <sup>3</sup>akoc@mku.edu.tr, <sup>4</sup>ayapici@mku.edu.tr

(Geliş/Received: 28.04.2015; Kabul/Accepted in Revised Form: 28.07.2015)

**ÖZ:** Organik Rankine çevrimlerinin güç tahmini için kullanılan simülasyon programlarında; sistem elamanlarının ideal yada ideale yakın olarak kabul edilen davranışlarının, gerçek davranışlarından farklı olmasından dolayı yüksek hata oranları ortaya çıkabilmektedir. Doğrusal davranışa sahip olmayan sistemlerde Yapay Sinir Ağları yöntemi ile yapılan tahminler gerçek sonuçlara daha yakın olabilmektedir. Bu çalışmada, deneysel bir organik Rankine çevrimlerinden alınan buharlaştırıcı atık ısı giriş-çıkış sıcaklıkları ile kütleli debisi, soğuk akışkan giriş-çıkış sıcaklıkları ile kütleli debisi öznitelikleri kullanılarak ağ eğitilmiştir. 10 kW'lık organik Rankine çevrimi için eğitilen ağ ile güç tahmini yapılarak deneysel sonuçlar ve tahmin sonuçları karşılaştırılmıştır. Çalışma sonucunda yapay sinir ağlarından elde edilen tahmin değerleri, deneysel verilerle kıyaslanmış ve tahminin performansını gösteren korelasyon katsayısı 0.99124 olarak hesaplanmıştır. Ayrıca ağa farklı deney verilerinin girişi gerçekleştirilerek ağın tahmin başarısı kontrol edilmiştir.

*Anahtar Kelimeler:* Organik Rankine çevrimi, Yapay sinir ağları, Atık ısı, Güç tahmini

### Power Prediction with Artificial Neural Network in Experimental Organic Rankine Cycle

**ABSTRACT:** In the simulation programs that used to estimate the power of the organic Rankine cycle; high error rates may have occurred due to accepting ideal or near-ideal behaviour differ from the actual behaviour of system components. Predictions made via artificial neural networks may be more close to actual results in the system which is of non-linear behaviour. In this study, network was trained by evaporator waste heat input- output temperatures and mass flow rate, cooling fluid input- output temperatures and mass flow rate taken from an experimental organic Rankine cycle. The power prediction was made with trained network and then the experimental and prediction results of the 10 kW organic Rankine cycle was compared. At the end of the study, the values obtained from artificial neural network were compared with experimental data and correlation coefficient which shows performance of network has calculated to be 0.99124. The prediction success of network was also checked via performing different test data input to the network.

*Key Words:* Organic Rankine cycle, Artificial neural networks, Waste heat, Power prediction

### GİRİŞ (INTRODUCTION)

Yüksek enerji tüketen üretim tesislerinde, gerek küresel rekabetin sağlanmasında gerekse pazara hakimiyetin korunmasında birim ürün maliyetleri önem arz etmektedir. Ham madde fiyatları, işçilik,

DOI: 10.15317/Scitech.2016116091

bakım onarım gibi birçok faktörün yanı sıra enerji maliyetleri en önemli giderler arasında ilk sıralarda yer almaktadır. Enerji maliyetleri her ne kadar ülkedeki serbest piyasa ile enerji üretim maliyetleri dikkate alınarak belirlense de, tüketimin azaltılmadığı sistemlerde enerji tasarruf yöntemlerinin uygulanması, tasarrufu göz ardı edilemeyecek kadar artırabilmektedir. Özellikle demir çelik sektörü, cam sektörü ve çimento sektörü gibi yüksek enerji tüketen ve üretim proseslerinde yüksek sıcaklıklara ihtiyaç duyulan tesislerin atık ısı geri dönüşüm sistemlerini kurması tasarruf yöntemlerinin en önemli adımlarından birisidir. Sanayi sektöründe uygulanabilecek atık ısı geri dönüşüm sistemlerinin en önemlilerinden biriside organik Rankine çevrimleridir. Düşük sıcaklıklardaki (80°C ve üzeri) ısı kaynaklarının kullanılabilirdiği bu çevrimler, dünyada henüz yaygın olarak kullanılmasa da birçok üretim tesislerinde örnek uygulamaların mevcut olduğu bilinmektedir (Yağlı ve ark., 2013). İçten yanmalı motorlarda organik Rankine çevrimlerinin kullanımı üzerine, üç farklı organik çevrim tasarımı, üç farklı organik çevrim akışkanı kullanarak analiz eden Vaja ve Gambarotta (2010); yapmış oldukları çalışmalar sonunda organik Rankine çevrimi kullanılan motorların toplam enerji verimini %12 artırdığı sonucuna ulaşmışlardır. Özden ve Paul (2011) Denizli Sarayköy bölgesinde açılmış olan 120°C sıcaklıktaki 50 lt/s debi kapasiteli jeotermal ısı kaynağı için analizler yapmış olup, bu analizler sonunda 750 kW net güce sahip santral kurulumu çalışmaları yürütmüşlerdir. Taljan ve arkadaşları (2012); ısı ve güç kombine sistemleri için organik Rankine çevrimi simüle etmiş ve bu tasarımı elektrik ve ısı satışından gelen gelirleri dikkate alarak optimize etmişlerdir. Çalışma, organik Rankine çevrimi ile tasarlanmış olan, ısı deposuz, ısı ve güç kombine sistemleri için aylık ısı talebinin 5 GWh den fazla olduğunu ve biyokütle fiyatının 17 €/MWh'den daha düşük olduğunu göstermiştir. Guo ve arkadaşları (2014) egzoz gazından ısı geri dönüşümü için, üç adet saf organik akışkan ve iki adet organik karışım akışkanı kullanılan organik Rankine çevrimlerinin bazı noktalardaki sıcaklık, kütleli debi ve çevrim ekserji değerleri kıyaslanmıştır. Isı kaynağı olarak yanma odası atık ısı kullanmakta olan çevrimlerde, buharlaşma basıncında reküperatör ısı değişiminin maksimum olduğu görülmüştür.

Organik Rankine sistemlerinin kurulumu öncesindeki tasarımlar her ne kadar çeşitli programlar ile simüle ediliyor olsa da, söz konusu yazılımlarda ideal olarak kabul edilen birçok sistem elemanı ve parametre kullanılmaktadır. Sistemin belirli aralıklarda ve doğrusal çalışacağı kabulüne göre yapılan simülasyonların sonucu, gerçek sonuçlardan bazen göz ardı edilemeyecek oranda uzaklaşmakta ve yapılan tahminler ile gerçek sistem sonuçları arasında büyük farklılıklar oluşabilmektedir. Bunun nedeni sistemler modellenirken sistem elemanları kaotik formda ifade edilseler dahi temellerinde doğrusal olmamalarıdır. Sistem üzerinde belirlenen giriş ve çıkış değişkenleri arasındaki bilinmeyen değerler ile tespiti kolay olmayan çalışma şartları, yapay sinir ağları (YSA) ile tahmine ve ön bilgiye gerek duyulmadan bulunabilmektedir. YSA doğrusal modelleme yapan programlardan farklı olarak verilerin doğrusal olmayan ilişkileri, belirsizlikleri ve kesinlikleri hallerinde de modelleme yapabilmektedir (Zhang ve ark., 1998). Yapay sinir ağları sistemlerini kullanarak eğitilmiş olduğu ağ ile absorpsiyonlu soğutma çevriminin termodinamik analizini yapmış olan Sözen ve arkadaşları (2003) bu sayede çok karmaşık yapıya sahip olan sistemlerin analizlerinin sadeleştirilmesini sağlamışlardır. Analiz için geri yayımlı öğrenme algoritması ile üç farklı değişken ve log-sigmoid değişken fonksiyonu kullanmışlardır. Ortalama hata %1.3'den daha az ve R<sup>2</sup> değerleri yaklaşık 0.9999 olarak tespit edilmiştir. Deneysel sonuçlar ile YSA ile elde edilen sonuçları karşılaştırıldığında etkinlik katsayısı, ekserji etkinlik katsayısı ve sirkülasyon oranlarındaki hata oranını sırasıyla %1.8, %4 ve %0.2'den daha düşük olduğu görülmüştür. Liu ve arkadaşları (2015) yapmış oldukları çalışmada dört farklı algoritmanın kullanıldığı yapay sinir ağı tabanlı rüzgar tahmin yazılımı geliştirmişlerdir. GD-ALR-BP, GDM-ALR-BP, CG-BP-FR ve BFGS algoritmalarının kullanıldığı çalışma sonucunda, CG-BP-FR algoritmasının en iyi performansı sağladığı görülmüştür.


Bu çalışmada, atık ısı geri kazanım potansiyelinin belirlenmesi için hazırlanmış olan 10 kW'lık bir organik Rankine çevrimi için deneyler yapılmış ve veriler kaydedilmiştir. Kaydedilen veriler kullanılarak YSA eğitilmiş olup, bu sayede farklı çalışma şartları için organik Rankine çevrimleri kullanılarak üretilebilecek güç miktarları tahmin edilmeye çalışılmıştır. Eğitilmiş olan YSA ile elde edilen tahminler, deney seti kullanılarak karşılaştırılmıştır. Deneysel veriler ile YSA tahminleri arasında

yapılmış olan karşılaştırma neticesinde, elde edilen değerlerin doğruluğa yakınlıkları ve sapma oranları grafiksel olarak incelenmiştir.

## MATERYAL ve METOT (MATERIAL and METHOD)

### Organik Rankine Çevrimi (Organic Rankine Cycle)

Düşük ve orta sıcaklıklardaki ısı kaynaklarının değerlendirildiği en önemli sistemlerden biriside organik Rankine çevrimleridir. Kullanılan donanımlar bakımından buharlı Rankine çevrimleri ile aynı olan organik Rankine çevrimlerinin, buharlı çevrimlerden temel farkı kullanılan çevrim akışkanıdır. Buharlı Rankine çevrimlerinde su buharı kullanılmakta iken organik Rankine çevrimlerinde organik akışkanlar kullanılmaktadır. Organik akışkanlar su ile kıyaslandığında daha düşük sıcaklıklarda kızgın buhar fazına geçebildiklerinden dolayı daha düşük sıcaklıklarda çevrimin çalışmasını mümkün kılmaktadır. Organik Rankine çevrimlerinde R245fa, tolüen, siklo-hekzan ve solkaterm yoğun olarak kullanılan organik akışkanlardan birkaçıdır.



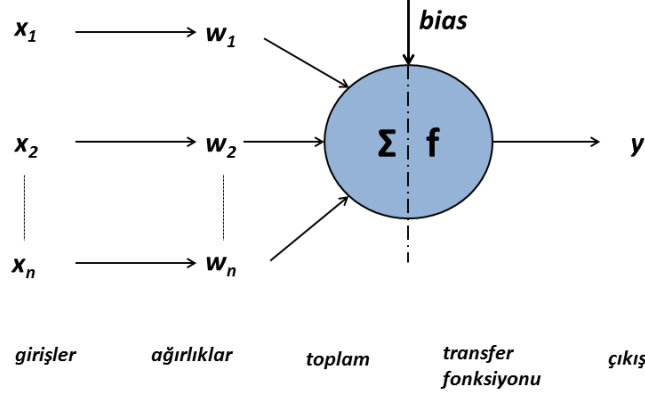
Şekil 1. Organik Rankine çevrimi şematik gösterimi ve sıcaklık-entropi grafiği (Schematic view of the organic Rankine cycle and temperature-entropy diagram)

Organik Rankine çevrimleri temel olarak buharlaştırıcı ünite, türbin, yoğusturucu ünite ve pompalardan oluşmaktadır. Isı değiştiricilerde ayrıca bu sistemlere eklenebilmektedir. Sıcak ısı kaynağından gelen jeotermal su ve egzoz gazları gibi atık ısı kaynakları buharlaştırıcıya girerek ısısının bir kısmını organik akışkana verir. Atık ısı kaynağından alınan ısı ile kızgın buhar ya da doymuş buhar fazına geçen akışkanın türbinden geçerken oluşturduğu dönme hareketi jeneratöre iletilir. Türbinden sonra ısı değiştiricide bir miktar ısısını pompadan çıkan soğuk akışkana vererek yoğusturucu üniteye geçer. Yoğuşmuş akışkan pompada basınçlandırılarak ısı değiştiriciye gönderilir. Türbin çıkışındaki çevrim akışkanından bir miktar ısı olarak ön ısıtma yapılır. Sonrasında sırasıyla ön ısıtıcı, buharlaştırıcı ve son ısıtıcıdan geçerek aynı akış şemasını kapalı çevrim içerisinde devam ettirir (Şekil 1).

### Yapay Sinir Ağları (Artificial Neural Network)

Yapay sinir ağları insan nöron yapısından yararlanılarak geliştirilen, öğrenme, tahmin etme ve eksik bilgi olsa dahi çıkarım yapma gibi özelliklere sahip, insan beynindeki sinir ağından esinlenerek ortaya çıkarılmış insan sinir sisteminin matematiksel bir modelidir. Karmaşık ilişkilerin değerlendirilmesinde birbirleri ile bağlantılı hücreler arasındaki ilişkiyi kullanarak tahmin, sınıflandırma, öğrenme gibi faaliyetlerde bulunabilen yapay sinir ağları son zamanlarda çokça tercih edilen optimizasyon tekniklerinden birisidir (Mert, 2014; Sarve, 2015).

Birbirleri ile fonksiyonel bir ilişki içerisinde bulunan yapay sinir ağları bir anlamda biyolojik sinir ağının matematiksel bir modelidir. Şekil 2’de yapay sinir ağının en temel elamanı olan bir nöronun yapısı görülmektedir.



Şekil 2. Yapay bir nöronun yapısı (Structure of artificial neuron) (Kalogirou, 1999)

Beş ana bileşenden oluşan nöron yapısında; girişler ( $x_1, x_2, \dots, x_n$ ), dış ortamdan veya diğer hücrelerden gelen bilgilerdir. Gelen bu bilgiler, ilgili ağırlıklarla ( $w_1, w_2, \dots, w_n$ ) çarpılarak toplama operatöründe toplanmaktadır. Ağırlıklar, eğitimdeki değişkenin sonuç üzerindeki etkisini göstermektedir. Toplama bias eklenerek elde edilen değer transfer fonksiyonundan geçirilerek nöronun çıkış değerine ulaşılmaktadır.

$$y = f(\sum_{i=1}^n x_i w_i + b) \quad (1)$$


20. yüzyılın ilk yarısında kullanılmaya başlanan ve kullanım alanı artarak genişleyen YSA, özellikle doğrusal olmayan problemlerin çözümünde kabul görmüş yöntemlerden birisidir. Güncel çalışmalarda karşılaşılan problemlere uygun olarak birçok yapay sinir ağı modeli geliştirilmiştir. Geliştirilen yapılar içerisinde çok yaygın olarak tercih edileni; bu çalışmada da kullanılan çok katmanlı ileri beslemeli yapay sinir ağlarıdır.

#### Organik Rankine Çevriminde Güç Tahmini İçin Yapay Sinir Ağı Yapısı (Structure of Artificial Neural Network for Power Prediction in Organic Rankine Cycle)

Eğitimde kullanılacak temel parametrelerin seçimi ağın performansına doğrudan etki ettiğinden, ağ eğitiminde kullanılacak öznitelikler büyük bir dikkatle seçilmelidir (Dogan ve ark., 2008). Deneysel organik Rankine çevrimi ile elde edilen gücün belirlenmesinde temel parametrelerden olan; buharlaştırıcı atık ısı giriş-çıkış sıcaklıkları ( $T_{b,g} - T_{b,\zeta}$ ) ile kütleli debisi ( $\dot{m}_b$ ), soğutucu akışkan giriş-çıkış sıcaklıkları ( $T_{y,g} - T_{y,\zeta}$ ) ile kütleli debisi ( $\dot{m}_y$ ) gibi öznitelikler belirlenerek elde edilebilecek güç tahmini yapılmıştır. YSA için tek gizli katmanın olduğu ileri beslemeli geri yayımlı ağ mimarisi kullanılmış, ara katman belirlenirken Eşitlik 2 ile ifade edilen ve ağın performansını gösteren ortalama karesel hata (MSE) değeri dikkate alınmıştır (Huan, 2014).

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_t - y_g)^2 \quad (2)$$


Yapılan eğitimler sonucunda 20 ara nörona sahip; ara katmanda tanjant-sigmoid, çıkış katmanında purelin transfer fonksiyonunun kullanıldığı ileri beslemeli geri yayımlı ağ mimarisi tercih edilmiştir. Gizli katman nöron sayısı belirlenirken ağ performansı ve gizli katman nöron sayısı arasındaki ilişki Şekil 3’de gösterilmektedir.



**Şekil 3.** Gizli katman nöron sayısı ve ortalama karesel hata arasındaki ilişki (*Relation between number of hidden layer neuron and mean square error*)

Oluşturulan ağda gizli katman için Eşitlik 4’de verilen tanjant sigmoid, çıkış katmanı için Eşitlik 5’de verilen purelin transfer fonksiyonu kullanılmıştır (Şekil 4). Transfer fonksiyonu dinamik değişimi -1 ile 1 aralığında olup ham veriler transfer fonksiyonunda bu aralıktan geçmektedir. Verilerin YSA’da kullanılabilmesi için normalize edilerek 0-1 aralığına çekilmesi gerekmektedir ve normalizasyon işlemi Eşitlik 3 kullanılarak yapılmaktadır.

$$X_{norm} = 1 - \frac{X - X_{min}}{X_{maks} - X_{min}} \quad (3)$$

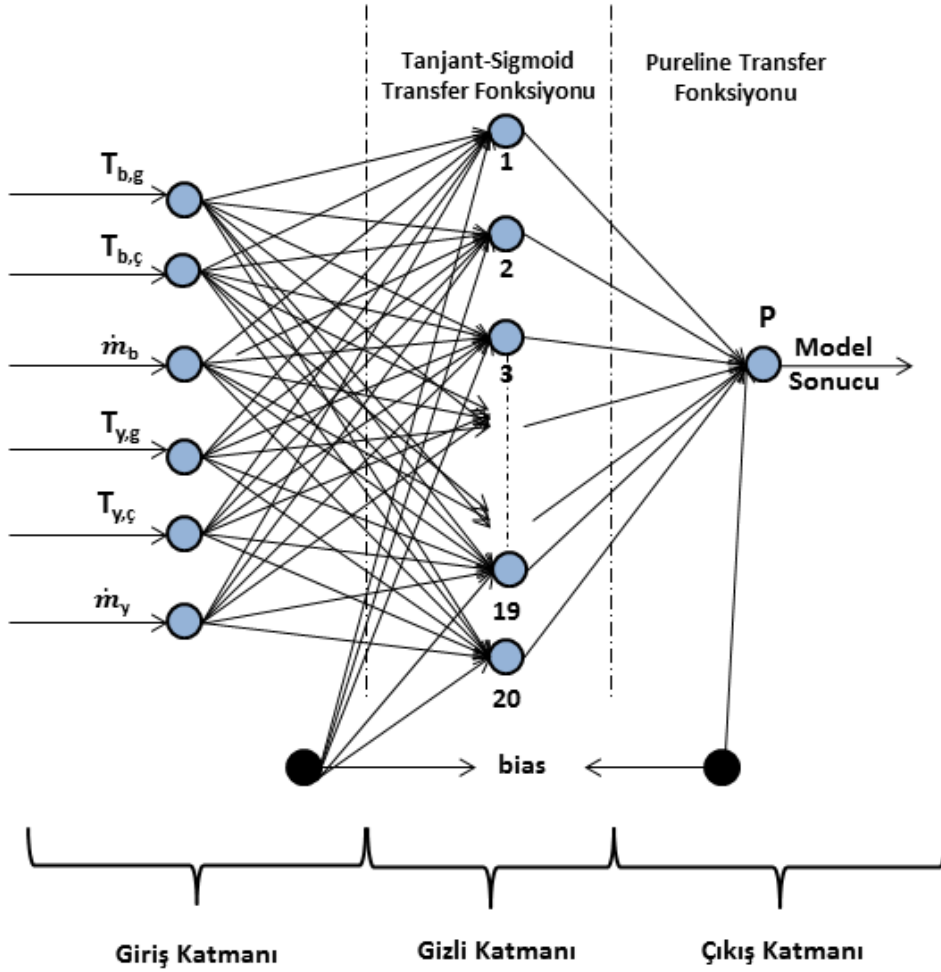


**Şekil 4.** Tanjant sigmoid ve purelin transfer fonksiyonu dinamik değişimleri (*Dynamic diversities of tanjant sigmoid and purelin transfer functions*)

$$f(x) = \frac{1}{1 + e^{-x}} \quad (4)$$

$$n = \begin{cases} 1 & n > 1 \\ n & -1 < n < 1 \\ -1 & n < -1 \end{cases} \quad (5)$$

Giriş değişkeni olarak belirlenen  $T_{b,g}$ ,  $T_{b,s}$ ,  $\dot{m}_b$ ,  $T_{y,g}$ ,  $T_{y,s}$ ,  $\dot{m}_y$  öz nitelikleri ile güç tahmini yapılan ileri beslemeli ağ mimarisi Şekil 5’de görülmektedir.



Şekil 5. Tahmin için geliştirilen ağ mimarisi (Structure of developed network for prediction)

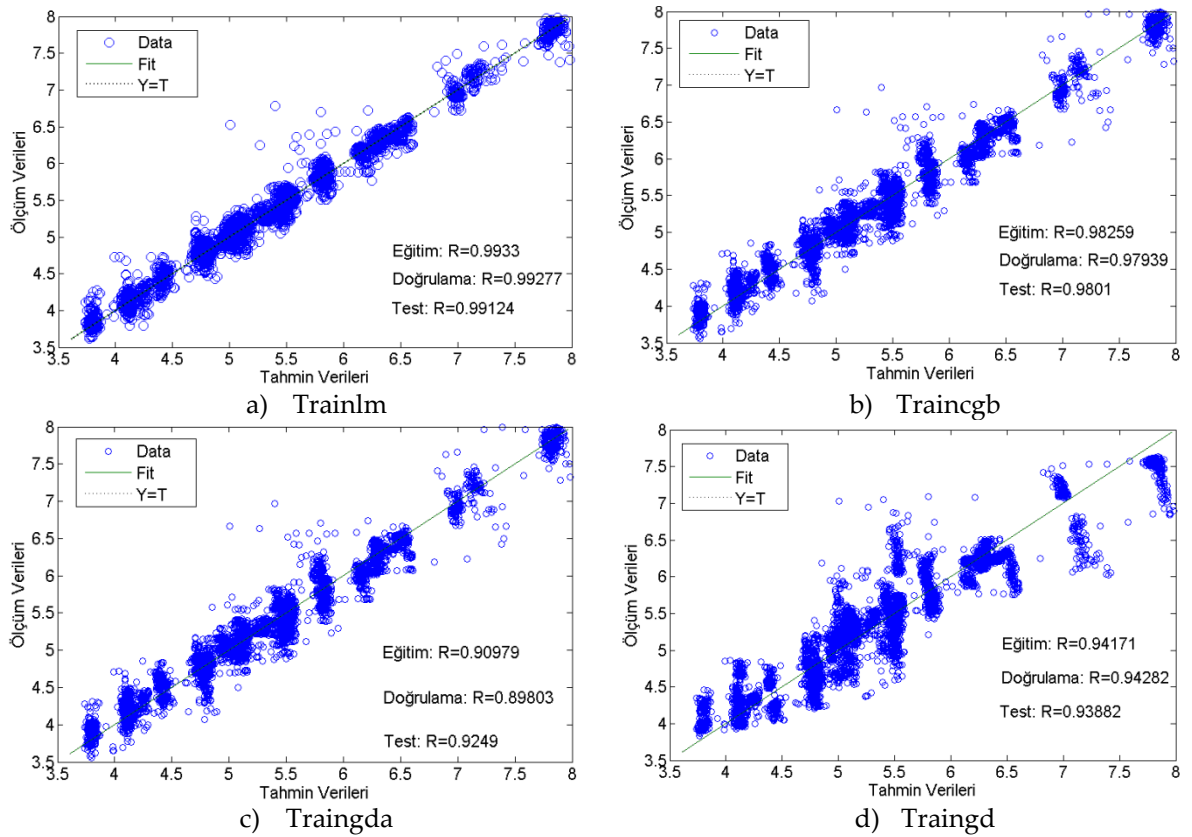
Geliştirilen yapay sinir ağının eğitimi için kullanılan deney setinden öz nitelik olarak seçilen altı bağımsız değişken (giriş katmanı) ve bir bağımlı değişken (çıkış katmanı) tanımlanmıştır. Belirlenen her bir değişken için 5412 farklı veri kullanılarak ağ eğitilmiştir. Giriş katmanında kullanılan her parametre normalize edilerek rastgele seçilen ağırlıklarla çarpma işlemi yapılmış olup ara katmandaki toplama işlemine bias eklenerek tanjant-sigmoid transfer fonksiyonuna ile işlenmiştir. Çıkış katmanındaki nörona geçen değişken; ilgili ağırlıklarla çarpılıp, çıkış katmanı biası da eklenerek purelin transfer fonksiyonundan geçirilmiştir. Ağ çıkışındaki değer denormalize edilerek gerçek değerle karşılaştırılarak yeni ağırlıklar belirlenmiştir. Tüm veri seti için aynı işlem tekrarlanarak ilk epoch gerçekleştirilmiştir. İşlem sonucunda; ortalama karesel hata değeri minimum ortalama karesel hata değerinden büyükse ikinci epoch'a geçilir, aksi durum için (minimum ortalama karesel hatanın işlem sonunda bulunan ortalama karesel hatadan büyük olması) ağın eğitimi tamamlanmıştır. Eğitim sonucunda, regresyon ve ortalama karesel hata değerlerine göre ağın performansı değerlendirilmiştir. Eğitim algoritması olarak Levenberg-Marquardt (Trainlm), Gradient Descent (Traingd), Gradient Descent with Adaptive Learning Rate (Traingda) ve Conjugate Gradient (Traingcb) geri yayımlı eğitim algoritmaları kullanılmıştır.

#### ARAŞTIRMA BULGULARI (RESEARCH FINDINGS)

Çalışma kapsamında, elde edilen gücü doğrudan etkileyen atık ısı ve soğutucu akışkan giriş - çıkış sıcaklıkları ile kütledebileri kullanılarak, güç tahmini için ileri beslemeli YSA modeli geliştirilmiştir.

Modelde deneysel olarak elde edilen 5412 tane veri seti kullanılmıştır. Bu verilerin %60'ı eğitim, %20'si geçerlilik (doğrulama) ve %20'si test için kullanılmıştır. Kullanılan YSA modeli için farklı sayıda ara katman nöronu deneyerek en uygun ara katman nöron sayısı belirlenmiştir. Uygun model eğitilirken iterasyon sayısı en fazla 1000 olarak belirlenmiştir. Sonuç olarak, 20 nörona sahip tek gizli katmanlı YSA modeli belirlenmiştir. YSA'yı eğitmek için ileri beslemeli geri yayımlı ağ mimarisi ile Levenberg-Marquardt (Trainlm), Gradient Descent (Traingd), Gradient Descent with Adaptive Learning Rate (Traingda) ve Conjugate Gradient (Traincgb) geri yayımlı eğitim algoritmaları kullanılmış; öğrenme oranı 0.01 olarak belirlenmiş, transfer fonksiyonu olarak da tüm algoritmalar için kendi içerisinde en iyi sonucu veren tanjant-sigmoid ve purelin transfer fonksiyonu seçilmiştir. R ve MSE performans kriterlerine göre değerlendirme yapılmıştır.

Tahmin verileri ile ölçüm verileri arasında doğrusal bir ilişki olup olmadığı incelenerek; eğitim, doğrulama ve test aşamaları için korelasyon katsayıları hesaplanmıştır (Şekil 6). Korelasyon katsayısı 0 ile 1 arasında değişmekte ve bu değer 1'e yaklaşması ağın başarısını göstermektedir (Doğan ve ark., 2008). Bu kapsamda elde edilen korelasyon katsayıları, ağın eğitimdeki başarısını göstermektedir.




Şekil 6. Korelasyon sonuçları (Correlation results)

Korelasyon ve ortalama karesel hata değerlerine göre performansı değerlendirilerek yapılan eğitim için farklı eğitim algoritmalarına göre elde edilen sonuçlar Çizelge 1'de verilmiştir.

Çizelge 1. Eğitim algoritmalarının performans değerleri (Performance values of training algorithms)

Eğitim Algoritması	Kolerasyon			MSE
	Eğitim	Doğrulama	Test	
Trainlm	0.9933	0.99277	0.99124	0.011996
Traincgb	0.98259	0.97939	0.9801	0.025726
Traingda	0.90979	0.89803	0.9249	0.19089
Traingd	0.94171	0.94282	0.93882	0.11876

YSA oluşturulduktan sonra 20 farklı veri seti ağına girilerek güç tahmin edilmiştir. Kullanılan eğitim algoritmaları ile elde edilen sonuçların ölçüm sonuçları ile karşılaştırıldığı grafikler Şekil 7'de gösterilmektedir. Korelasyon ve ortalama karesel hata değerlerinden elde edilen sonuca göre en iyi eğitim algoritması Levenberg-Marquardt olarak belirlenmiştir.



Şekil 7. Farklı veri seti ile yeni tahminler (New predictions with different data set)

Şekil 7'de görüldüğü üzere eğitim ve gerçek sonuçlar ve tahmin sonuçları arasında en yakın benzerlik %1.09 hata ile Levenberg-Marquardt algoritmasının kullanıldığı ağıda elde edilmiştir. Ağına ilişkin ağırlıklar ve biaslar Çizelge 2'de verilmektedir.



**Çizelge 2.** Eğitim sonucu ulaşılan ağırlıklar (*Evaluated weights and bias' at the end of training*)


<i>i</i>	W1				B1		W2	B2
	$T_{b,g}$ (°C)	$T_{b,c}$ (°C)	$\dot{m}_b$ (kg/s)	$T_{y,g}$ (°C)	$T_{y,c}$ (°C)	$\dot{m}_y$ (kg/s)		
1	2.7058	-10.1528	1.412	6.9359	-11.4272	-7.3118	-7.891	-0.2213
2	0.38646	0.13977	-1.6009	3.0684	0.64012	-6.4585	1.5462	1.0647
3	6.5328	-7.5217	0.092843	4.7573	3.5757	-0.88853	-2.4705	-1.0194
4	-7.4131	15.5486	0.39813	5.085	-3.4531	2.1038	-3.6661	0.32301
5	-6.0354	11.1843	-0.64387	5.3736	-1.7163	-0.00366	-3.7345	-0.77071
6	5.8012	4.9134	0.3668	-1.0704	2.2352	-4.4167	-3.971	3.518
7	2.6048	30.6145	2.4522	-18.649	9.2503	-7.0424	-8.8168	0.15262
8	8.1641	15.7108	5.6166	14.434	-7.3541	1.5577	-22.4786	-0.14669
9	1.4957	7.5146	-0.13153	-2.5622	5.5347	6.1983	3.8554	-0.25252
10	7.8146	-5.6775	0.30752	8.9532	2.4961	-9.7718	-13.0034	-2.8846
11	5.7127	6.5417	0.57347	-2.4034	2.6467	-4.8185	-3.9528	-3.4137
12	0.93501	-2.4718	-0.15879	4.8819	2.565	-0.4121	-1.8744	1.2227
13	9.5416	-9.6593	0.53596	-0.80082	2.8649	-0.29049	1.2093	0.35073
14	-0.84164	-0.77909	0.75029	0.63414	-3.045	4.7658	-0.47607	1.7202
15	-0.71231	-8.7213	-2.3806	0.1452	21.5014	-1.7768	-11.1721	4.0451
16	-12.4061	-6.3744	-0.43545	2.3809	-7.0677	3.8581	4.5796	-0.76278
17	-7.7293	5.6029	-0.30731	-9.4282	-2.5147	10.4552	13.7192	-2.8533
18	0.024611	0.44177	-0.12113	1.1863	0.48164	0.26364	2.5416	-0.86307
19	0.10665	9.0373	2.3517	0.12187	-21.4961	1.6298	11.1751	4.0718
20	0.25192	4.6133	0.85038	0.81325	-2.7161	1.6083	-2.7118	0.61891

Ağ eğitimi için kullanılan 5412 adet eğitim setinin minimum ve maksimum değerleri Çizelge 3' de verilmektedir.

**Çizelge 3.** Giriş ve çıkış parametrelerinin maksimum ve minimum değerleri (*Maximum and minimum values of input and output parameters*)

Değer	$T_{b,g}$ (°C)	$T_{b,c}$ (°C)	$\dot{m}_b$ (kg/s)	$T_{y,g}$ (°C)	$T_{y,c}$ (°C)	$\dot{m}_y$ (kg/s)	<i>P</i> (kW)
<b>Maksimum</b>	16.3	19.7	46.7	128.9	117.4	3.2	7.98
<b>Minimum</b>	6.1	7.3	7.3	112.2	88.5	0.5	3.74

Eğitim sonucu elde edilen tahmin verileri ve ölçüm verilerinin karşılaştırılması Şekil 8'de görülmektedir ( Mert ve ark., 2014; Sarve ve ark., 2015).



Şekil 8. Tahmin ve ölçüm verilerinin karşılaştırılması (Comparison of prediction and measurement data)

### SONUÇ ve TARTIŞMALAR (RESULTS and DISCUSSIONS)

Tüklenen enerji kaynaklarına rağmen gün geçtikçe artmakta olan enerji ihtiyacının göz ardı edilemeyecek bir kısmının organik Rankine çevrimleri gibi atık ısı geri dönüşüm sistemleri ile geri kazanılması; gerek dünya, gerekse sanayi enerji politikası açısından büyük önem arz etmektedir. Enerjiyi yoğun tüketen sanayi sektörlerinin var olan atık ısılarının geri dönüştürülebilirlik oranlarının belirlenmesinde, birçok problemin çözümünde de yaygın olarak kullanılmakta olan YSA ile parametre tahmini yapılmıştır. Deneysel bir organik Rankine çevriminden alınan  $T_{b,g}$ ,  $T_{b,s}$ ,  $\dot{m}_b$ ,  $T_{y,g}$ ,  $T_{y,s}$ ,  $\dot{m}_y$  verileri ileri beslemeli olarak YSA ile eğitilmiş dört farklı eğitim algoritması kullanılarak eğitilen ağ için en iyi performansı veren Levenberg-Marquardt öğrenme algoritması ile elde edilen ağın performansını gösteren korelasyon katsayısı 0.99124 olarak hesaplanmıştır. Bu değer 1'e yaklaşması ağın başarısını göstermekte olup hesaplanan değer ağın eğitimin başarılı olduğunu sonucunu vermektedir. Ağın farklı veri setine cevabı incelenmiş ve gerçek sonuçlarla karşılaştırılmıştır. Karşılaştırma sonucu tüm veri seti için hata oranları bulunarak, ortalama yüzde hata değeri % 1.09 olarak hesaplanmıştır. Sonuç olarak oluşturulan ağın YSA ile tahminin başarılı sonuçlar verdiği görülmüştür. Elde edilen doğruluğa yakınlığı tespit edilen sonuçlar kullanılarak, sisteme yüksek debili atık ısı girdiğinde üretililecek gücün tahmini gerçeğe yakın elde edilmiştir. Bu sayede sistem parametreleri YSA'ya göre ayarlanarak güç hesabı yapılabileceği anlaşılmıştır.

### KAYNAKLAR (REFERENCES)

- Dogan, E., et al. (2008) "Application of artificial neural networks to estimate wastewater treatment plant inlet biochemical oxygen demand." *Environmental progress* 27.4: 439-446.
- Guo, C., Du, X., Yang, L. ve Yang, Y. (2015) "Organic Rankine cycle for power recovery of exhaust flue gas", *Applied Thermal Engineering*, 75 (2015) 135-144.
- Huan, H, et al. (2014) "Strength Prediction of Aluminum–Stainless Steel-Pulsed TIG Welding–Brazing Joints with RSM and ANN." *Acta Metallurgica Sinica (English Letters)* 27.6: 1012-1017.
- Kalogirou, S. A. (1999) "Applications of artificial neural networks in energy systems." *Energy Conversion and Management* 40.10: 1073-1087.
- Liu, H., Tian H., Li,Y. ve Zhang, L. (2015) "Comparison of four Adaboost algorithm based artificial neural networks in wind speed prediction", *Energy Conversion and Management*, 92 (2015) 67-81
- Mert, I., and Arat, H. T., (2014) "Prediction of heat transfer coefficients by ANN for aluminum & steel material." *International Journal* 5.2: 2305-1493.

- Özden, H. ve Paul, D. (2011) "Organik Rankine çevrim teknolojisiyle düşük sıcaklıktaki kaynaktan faydalanılarak elektrik üretimi. Örnek çalışma: Sarayköy jeotermal santrali", X. Ulusal Tesisat Mühendisliği Kongresi, İzmir, 13/16 Nisan 2011, pp. 101-108.
- Sarve, Shriram, A., Sonawane, S. and Varma, M. N. (2015). "Ultrasound assisted biodiesel production from Sesame (*Sesamum indicum* L.) oil using Barium hydroxide as a heterogeneous catalyst: Comparative assessment of prediction abilities between Response surface methodology (RSM) and Artificial neural network (ANN)." *Ultrasonics Sonochemistry*
- Sözen, A., Arcaklioğlu, E. ve Özalp, M. (2003) "A new approach to thermodynamic analysis of ejector-absorption cycle: artificial neural networks", *Applied Thermal Engineering*, 23 (2003) 937-952.
- Taljan, G., Verbic, G., Pantos, M., Sakulin, M. ve Fickert, L. (2012) "Optimal sizing of biomass-fired organic Rankine cycle CHP system with heat storage", *Renewable Energy*, 41 (2012) 29-38.
- Vaja, I. ve Gambarotta, A. (2010) "Internal combustion engine (ICE) bottoming with organic Rankine cycle (ORCs)", *Energy*, 35 (2010) 1084-1093
- Yagli, H., Karakus, C., Koc, A., Pulyaev, S. and Akgöz, O. (2013) "Usability of waste heat by organic Rankine cycle and exergy analysis", *Proceeding of the UTES'2013 IX. Clean Energy Symposium, Konya, Turkey*, pp.394-401.
- Zhang, G., Patuwo, B.E. ve Hu, M.Y., "Forecasting with artificial neural networks: the state of the art", *Int. Journal of Forecasting*, 14 (1998) 35-62.