

PAPER DETAILS

TITLE: Farkli performans metriklerinin buharlasma modellemesi üzerindeki etkisinin incelenmesi

AUTHORS: Volkan YILMAZ

PAGES: 472-486

ORIGINAL PDF URL: <https://dergipark.org.tr/tr/download/article-file/2778837>



Farklı performans metriklerinin buharlaşma modellemesi üzerindeki etkisinin incelenmesi

Investigation of the effect of different performance metrics on evaporation modeling

Volkan Yılmaz*

¹ Konya Teknik Üniversitesi, İnşaat Mühendisliği Bölümü, 42250, Konya Türkiye +905327881182

Öz

Bu çalışmada Yapay Arı Kolonisi (YAK) optimizasyon algoritması ile Anamur meteoroloji istasyonu verileri kullanarak aylık toplam açık yüzey buharlaşması modellenmiştir. Çalışmalarda Determinasyon Katsayısı (R^2), Nash-Sutcliffe Etkinlik katsayısı (NSE), Ortalama Karesel Hata (Mean Squared Error, MSE) ve Yanlılık Yüzdesi (Percent Bias, PBIAS) metrikleri kullanılarak; R^2 ve NSE maksimizasyonu ile MSE, MSE/R^2 , $MSE/+NSE$ ve PBIAS minimizasyonu uygulanarak seçilen performans metriklerinin sonucu ne derecede etkilendiği araştırılmıştır. Çalışmalar sonucunda öncelikle YAK algoritmasıyla başarılı buharlaşma modellerinin oluşturulabileceği görülmüş olup, seçilen performans metriklerinin sonucu önemli derecede etkilendiği çıktısı elde edilmiştir. Kullanılan amaç fonksiyonları içerisinde R^2 maksimizasyonu ile elde edilen modellerde düşük tahmin/yüksek tahmin probleminin meydana geldiği ve PBIAS minimizasyonunun ise oldukça başarısız modeller ürettiği görülmüş olup en başarılı modellerin $MSE/+NSE$ amaç fonksiyonu ile elde edildiği sonucuna ulaşılmıştır. Bu alanda literatürde daha önce uygulanmamış olan $MSE/+NSE$ metriğinin başarılı sonuçlar elde ettiğinin gösterilmiş olması mevcut çalışmanın ana çıktısı olarak kabul edilmekte ve bu durumun çalışmanın yenilikçi kısmını oluşturduğu düşünülmektedir.

Anahtar kelimeler: Buharlaşma, Optimizasyon, Performans metrikleri, Yapay arı kolonisi

Abstract

In this study, monthly total open surface evaporation was modeled using Anamur meteorological station data with Artificial Bee Colony (ABC) optimization algorithm. Coefficient of Determination (R^2), Nash-Sutcliffe Efficiency (NSE) coefficient, Mean Squared Error (MSE) and Percent Bias (PBIAS) metrics were used in the studies. With the help of these metrics, R^2 and NSE maximization and MSE MSE/R^2 $MSE/+NSE$ and PBIAS minimization were applied and how the selected performance metrics affected the result was investigated. Among the objective functions used, it has been seen that the models obtained by R^2 maximization have underestimation/overestimation problem and PBIAS minimization produces very unsuccessful models, and it has been concluded that the most successful models are obtained with $MSE/+NSE$ objective function. The fact that the $MSE/+NSE$ metric, which has not been applied before in the literature in this field, has been shown to achieve successful results is accepted as the main output of the current study and it is thought that this situation constitutes the innovative part of the study.

Keywords: Artificial bee colony, Evaporation, Optimization, Performance metrics

1 Giriş

Temel anlamda sıvı halde bulunan su moleküllerinin enerjisinin artmasıyla birlikte gaz fazına geçmeleri buharlaşma olarak tanımlanmaktadır. Biriktirme haznelerinin kapasitelerinin belirlenmesinde, havza verimlilik hesaplamalarında ve tarımsal su tüketiminde dikkate alınan en önemli fenomenlerden birisi olan buharlaşma aynı zamanda zemin ile atmosfer arasındaki ısı akışını sağlayan ana parametredir [1]. Zemin özellikleri, meteorolojik değişkenler, bitki deseni ve benzeri ana değişkenlerin yanında birçok farklı parametre tarafından yüksek derecede etkilenen buharlaşma olgusunun, su çevrimi içerisindeki diğer parametrelere kıyasla tahmin

edilmesi en zor ve en karmaşık değişken olduğu ifade edilmiştir [2].

Su kaynaklarının korunması alanında yapılan hesaplamalar büyük oranda buharlaşma olgusunu da içinde barındırmaktadır. Büyük biriktirme haznelerinden her yıl milyonlarca metreküp temiz su buharlaşma yoluyla atmosfere karışmakta [3] ve yüksek maliyetler harcanarak derlenen bu suların etkin bir şekilde yararlanma imkânı giderek azalmaktadır. Diğer taraftan su kaynaklarının büyük bir kısmının harcandığı tarımsal sulama alanında buharlaşma fenomeni oldukça önemli bir değişken olarak denkleme girmektedir, toplam buharlaşma miktarının bir göstergesi olan evapotranspirasyon kayıpları sulama suyu ihtiyacını belirleyen en temel parametrelerden birisidir. Sınırlı

* Sorumlu yazar / Corresponding author, vyilmaz@ktun.edu.tr (V. Yılmaz)

Geliş / Received: 17.11.2022 Kabul / Accepted: 03.02.2023 Yayınlanma / Published: 15.04.2023

doi: 10.28948/ngumuh.1206278

durumda bulunan su kaynaklarımız giderek artan nüfus ile birlikte incelendiğinde su kaynaklarının korunması başlığının her geçen gün daha da önemli hale geldiği görülebilir. Bu yüzden buharlaşma gibi olguların daha detaylı incelenmesi ile daha başarılı modelleme ve tahminler yapılarak temiz suya erişimin sürdürülebilir bir şekilde devamlılığı sağlanabilir.

Doğada gerçekleşen buharlaşmanın tam olarak ölçümü için temelde dolaylı ve direkt yöntemler olmak üzere iki farklı yaklaşım uygulanır [4]. Direkt yöntemlerde buharlaşma tavaşı adı verilen serbest yüzeyli kaplarda meydana gelen buharlaşma miktarları ölçülür, bunların arasında en bilindik olanı A sınıfı buharlaşma tavaşıdır [3]. Dolaylı yöntemlerde ise buharlaşmayı etkileyen parametreler kullanılarak Penman–Monteith, Priestley–Taylor, Blaney–Criddle eşitlikleri gibi matematiksel modeller kullanılır [5]. Fakat buharlaşma olgusunun çok farklı parametre tarafından etkileniyor olması ve karmaşıklığının yanında modern modelleme ve tahmin yöntemlerinde meydana gelen gelişmelere paralel olarak araştırmacıların zaman içerisinde başta yapay zekâ yöntemleri olmak üzere zaman serileri ve optimizasyon algoritmaları gibi gelişmiş uygulamalara yönelmiş oldukları görülmektedir.

Literatürde bu alanda yapılmış olan çalışmalara bakıldığında ilk zamanlarda Lineer/Nonlineer regresyon yöntemlerinin [6] ve devamında başta Yapay Sinir Ağları [7,8] olmak üzere Destek Vektör Makinaları [4,9] ve Bulanık Mantık [10,11] gibi yapay zekâ yöntemlerinin kullanıldığı görülmektedir. Özellikle son yıllarda optimizasyon algoritmalarının farklı problemlerde başarılı çözümlere ulaşabilmiş olmaları sebebiyle başta doğadaki canlıların davranışlarından esinlenerek ortaya atılan Metasezgisel Optimizasyon Algoritmaları olmak üzere farklı optimizasyon tekniklerinin de buharlaşma olgusunun modellenmesi ve tahmininde kullanılmış olduğu görülmektedir [12-16].

Mevcut çalışma ise bu noktada literatüre bir katkı sağlamak amacıyla kurgulanmıştır. Optimizasyon algoritmalarıyla buharlaşma modellemesi yapılan diğer çalışmalar incelendiğinde genel olarak yöntemlerin başarılarının birbirleriyle ya da diğer yapay zekâ teknikleriyle kıyaslandığı görülmektedir. Bu noktada optimizasyon algoritmalarının başarısını yüksek düzeyde etkileyen performans metrikleri üzerine yapılmış bir çalışmaya rastlanılmamıştır. Zira optimizasyon algoritmaları genel olarak kullandıkları amaç fonksiyonu doğrultusunda en iyi bulmaya yönelik olarak tasarlanan tekniklerdir ve amaç fonksiyonunun tercihi model başarısını doğrudan ilgilendirmektedir. Bu açıdan mevcut çalışmada R^2 , NSE, MSE ve PBIAS metrikleri kullanılarak sırasıyla R^2 ve NSE maksimizasyonu ve MSE, MSE/R^2 , $MSE/+NSE$ ve PBIAS minimizasyonu gerçekleştirilmiştir. Yapılan çalışmalarda son zamanlarda birçok problemde başarılı sonuçlara ulaşan YAK optimizasyon algoritması kullanılmıştır. Elde edilen veriler istatistiki göstergeler yardımıyla sayısal olarak, zaman serisi grafikleri ve Taylor diyagramlarıyla da görsel olarak incelenmiştir. Ulaşılan sonuçlardan yola çıkarak

kullanılan amaç fonksiyonlarının buharlaşma modellemesini ne derecede etkilediği araştırılmıştır.

2 Materyal ve metod

2.1 Materyal

Çalışma için kullanılan veriler Meteoroloji Genel Müdürlüğü (MGM)'ne bağlı 17320 numaralı Anamur meteoroloji gözlem istasyonundan ($37^{\circ}04'K$ $32^{\circ}51'D$) alınmıştır. İlgili meteoroloji istasyonunun Türkiye üzerindeki konumu aşağıda Şekil 1'de gösterilmiştir. Buharlaşma ile ilgili yapılan çalışmalarda özellikle sert karasal iklimin hâkim olduğu bölgelerde kış mevsimlerinde buharlaşma kabındaki suyun donması sebebiyle ölçüm yapılamadığı ifade edilmektedir [3]. Bu sebeple daha ılıman olan Akdeniz ikliminin hâkim olduğu bu bölge çalışma için tercih edilmiştir. Çalışmada 2004-2019 yılları arasında ait aylık veriler kullanılmıştır. Kullanılan meteorolojik parametrelere ait tanımlayıcı ve istatistiki bilgiler Tablo 1'de ve çalışma bölgesinde ölçülmüş buharlaşma değerlerine ait zaman serisi grafiği ise Şekil 2'de gösterilmiştir.

Tablo 1'de gösterilen bilgiler incelendiğinde öncelikle TS ve S parametrelerinin B ile yüksek düzeyde ilişki içerisinde olduğu görülmektedir. Şekil 2'deki zaman serisi grafiğinde de B değerlerinin sıcaklık değişimine benzer bir dağılım sergilediği ve daha çok mevsimsel etkilerin etkisi altında olduğu anlaşılmaktadır. Diğer taraftan 16 yıllık zaman diliminde ölçülen minimum B değerinin 42mm olması daha önce ifade edilen buharlaşma kabındaki suyun donmasından dolayı ölçüm yapılamaması probleminin meydana gelmemiş olduğunu göstermektedir. Çarpıklık ve Basıklık değerleri için Bulmer [17]'in ± 1 aralığını, Tabachnick ve Fidell [18]'in ise ± 1.5 aralığını normal dağılım bölgesi olarak önerdiği dikkate alınacak olursa özellikle Y parametresinin yüksek değerler üreterek diğer parametrelere kıyasla normal dağılımdan daha uzak bir davranış sergilediği de görülmüştür.

2.2 YAK optimizasyon algoritması

İlk kez Karaboğa [19] tarafından literatüre kazandırılmış olan YAK optimizasyon algoritması arıların doğadaki yiyecek arama davranışlarından esinlenilerek geliştirilmiş olan bir Metasezgisel Optimizasyon Algoritmasıdır. Nümerik problemlerde başarılı sonuçlar üreten YAK optimizasyon algoritması [20] daha sonraları birçok mühendislik problemine de uyarlanmış ve başarılı sonuçların elde edildiği görülmüştür [21-23].

YAK yöntemi temelde İşçi arı, Gözcü arı ve Kâşif arı fazı olmak üzere üç ayrı faz şeklinde çalışmaktadır. Algoritmada çözüme başlanırken öncelikle rastgele başlangıç noktaları Denklem (1) yardımıyla belirlenir. Burada FN (FoodNumber) besin kaynağı sayısı, D ise optimize edilecek parametre sayısıdır. x_j^{min} ve x_j^{max} ise arama uzayının alt ve üst limitini ifade eder.

$$x_{ij} = x_j^{min} + rand(0,1)(x_j^{max} - x_j^{min}) \quad (1)$$

$i = 1.....FN; j = 1.....D$

Tablo 1. Çalışmada kullanılan meteorolojik verilere ait tanımlayıcı ve istatistiki bilgiler

Parametre	Kısaltma	Minimum	Ortalama	Maksimum	Std. Sapma	Çarpıklık	Basıklık	B ile Korelasyon
Ortalama 10 cm Toprak Sıcaklığı (°C)	TS	8.80	22.88	36.60	8.52	0.03	-1.44	0.91
Ortalama Nispi Nem (%)	NN	42.70	65.95	86.00	8.42	0.09	-0.24	0.04
Ortalama Rüzgâr Hızı (m/sn)	RH	1.20	2.15	3.00	0.38	0.06	-0.66	-0.06
Ortalama Sıcaklık (°C)	S	10.40	20.21	30.70	6.17	0.10	-1.38	0.87
Toplam Yağış (mm)	Y	0.00	76.75	545.20	100.62	1.85	3.78	-0.68
Toplam Açık Yüzey Buharlaşması (mm)	B	42.00	128.11	253.30	55.14	0.44	-0.91	1.00

Probleme ait rastgele çözüm noktalarını ifade eden başlangıç noktalarına ait Z amaç fonksiyonu (Denklem (6-11)) ve fitness (uygunluk) değerleri (Denklem (2)) hesaplanır ve en başarılı sonucu veren kaynak ve bu kaynağa ait sonuç değeri ortak hafızaya kaydedilir. Denklem (2)'de görülen f_i değerleri amaç fonksiyonu ile üretilen sonuçlardır. Bu aşamadan sonra kovandan ayrılarak rastgele besin yeri arayan arılar artık işçi arı haline gelmiş olurlar, bu aşamadan sonra artık işçi arı fazı başlar. Bu fazda işçi arılar daha önce rastgele bir şekilde elde edilen besin yerlerinin komşuluğunda Denklem (3)'ü kullanarak daha kaliteli besin yerleri yani çözüm kümeleri aramaya başlarlar.

$$fitness_i = \begin{cases} 1/(1 + f_i) & f_i \geq 0 \\ 1 + abs(f_i) & f_i < 0 \end{cases} \quad (2)$$

$$v_{ij} = x_{ij} + \phi_{ij}(x_{ij} - x_{kj}) \quad (3)$$

Bu fazda işçi arılar x_{ij} komşuluğunda v_{ij} kaynağını aramaya başlarlar. Denklem (3)'de j , $[1,D]$ aralığında üretilmiş bir tamsayıdır, ϕ_{ij} ise $[-1,+1]$ aralığında rastgele değerler alır. Yine Denklem (3)'teki k ifadesi rastgele belirlenen komşu çözümü ifade etmektedir. İşçi arı fazının sonunda Denklem (3) yardımıyla yapılan konum güncellemeleri tamamlandıktan sonra elde edilen yeni besin noktalarına ait amaç fonksiyonu ve fitness değerleri hesaplanır, daha iyi çözüm noktaları elde edildiyse bu noktalar eskisinin yerine kaydedilir. Herhangi bir kaynak için daha kaliteli yeni bir kaynak bulunamadıysa ilgili besin kaynağının yani çözüm kümesinin sayaç değeri bir arttırılır. Bu aşamadan sonra Gözcü arı fazı başlar


Gözcü arı fazında her bir kaynak için Denklem (4) yardımıyla olasılık değerleri hesaplanır ve $[0,1]$ aralığında rastgele bir sayı üretilir. Herhangi bir kaynak için hesaplanan olasılık (p_i) değeri, üretilen bu sayıdan büyükse gözcü arı Denklem (3)'ü kullanarak bu kaynak bölgesi etrafında yeni bir çözüm üretir. İşçi arı fazının sonunda olduğu gibi bu fazdan sonra da sayaç mekanizması çalışır ve elde edilen daha kaliteli besin yerleri eskisinin yerine kaydedilir.

$$p_i = \frac{fitness_i}{\sum_{i=1}^{FN} fitness_i} \quad (4)$$



Şekil 1. MGM 17320 numaralı Anamur meteoroloji gözlem istasyonunun konumu

Daha önce açıklanan sayaç mekanizması eğer önceden belirlenen bir limit değerini aşarsa Kâşif arı fazı başlar ve ilgili noktadaki besinin tükenmiş olduğu anlaşılır, bu durumda yeni bir kâşif arı kovandan ayrılarak Denklem (1) doğrultusunda yeni bir kaynak arayışına başlar. Kâşif arıların kullanımında gerekli olan limit değeri için genel olarak FNxD değeri önerilmektedir [20]. Belirli bir sonuç değerine ulaşıldığından ya da belirli bir iterasyon sayısı tamamlandığında işlemler durdurulur.



Şekil 2. Çalışma bölgesi için B'ye ait aylık zaman serisi grafiği

2.3 Model yapısı

Mevcut çalışmada gözlenen B değerleri y_g ve YAK optimizasyon algoritması ile üretilmiş modeller ile elde edilen B değerleri y_m ile ifade edilecek olursa, model yapısı aşağıda [Denklem \(5\)](#)'te gösterildiği şekilde kurulmuştur.

$$y_m = \beta_1 x_{TS} + \beta_2 x_{NN} + \beta_3 x_{RH} + \beta_4 x_S + \beta_5 x_Y \quad (5)$$

[Denklem \(5\)](#)'te gösterilen y_m modelleri için YAK optimizasyon algoritması yardımıyla en uygun β değerlerinin $[x_j^{\min}, x_j^{\max}]$ aralığında bulunması amaçlanmaktadır. Arama işleminde YAK yönteminin ihtiyaç duyduğu Z amaç fonksiyonu aşağıda gösterildiği gibi 6 farklı şekilde oluşturulmuştur.

Çalışmada kullanılan ilk amaç fonksiyonu (Z_1) literatürde yaygın bir şekilde kullanılan Determinasyon Katsayısıdır (R^2), [Denklem \(6\)](#)'da gösterilen R^2 değeri model sonucu üretilmiş olan değerler ile gözlenen değerler arasındaki ilişkinin incelenmesini sağlayan bir metrik olup $[0;1]$ aralığında değerler alır. R^2 değerinin 1'e yaklaşması her iki veri seti arasındaki ilişkinin kuvvetlendiğini gösterirken genel olarak bu değerin 0.5'in üzerine çıkması kabul edilebilir bir çözüm için yeterli görülmüştür [\[24\]](#). [Denklem \(6-8\)](#)'deki k değerleri veri sayıdır.

$$Z_1 = R^2(y_g, y_m) = \frac{[\sum(y_g y_m) - (\sum y_g)(\sum y_m)/k]^2}{(\sum y_g^2 - \frac{(\sum y_g)^2}{k}) \cdot (\sum y_m^2 - \frac{(\sum y_m)^2}{k})} \quad (6)$$

Çalışmada kullanılan ikinci amaç fonksiyonu (Z_2) Nash-Sutcliffe Etkinlik (NSE) Katsayısıdır [\[25\]](#). [Denklem \(7\)](#)'de gösterilen NSE metriği $[-\infty; 1]$ aralığında değerler alır. Burada NSE için 0 ve 1 aralığındaki değerler genellikle kabul edilebilir bir performans göstergesi olarak görülürken [\[26\]](#) NSE'nin 1 olması mükemmel uyum olduğu anlamına gelir.

$$Z_2 = NSE(y_g, y_m) = 1 - \left[\frac{\sum(y_g - y_m)^2}{\sum(y_g - \bar{y}_g)^2} \right] \quad (7)$$

Çalışmada kullanılan bir diğer amaç fonksiyonu (Z_3) Ortalama Karesel Hata (Mean Squared Error, MSE)

metriğidir. [Denklem \(8\)](#)'de gösterilen MSE metriği gözlenen verilerle model sonucu elde edilen veriler arasındaki hataların karelerinin ortalamasıdır. Verilerin özelliğine göre değişebilen MSE metriği küçüldükçe hata değerlerinin azaldığı, büyüdüğü ise arttığı kabul edilir.

$$Z_3 = MSE(y_g, y_m) = \frac{1}{k} \cdot \sum (y_g - y_m)^2 \quad (8)$$

Çalışmada kullanılan bir sonraki amaç fonksiyonu (Z_4), [Denklem \(9\)](#)'da gösterilen MSE/ R^2 metriğidir. Burada Z_4 amaç fonksiyonunun minimize edilmesiyle düşük MSE ve yüksek R^2 değerlerinin elde edilebilmesi amaçlanır. Bu sayede daha az hata değeri ile daha yüksek ilişki yapısı gösteren modellerin üretilmesi hedeflenmektedir.

$$Z_4 = \frac{MSE(y_g, y_m)}{R^2(y_g, y_m)} \quad (9)$$

Çalışmada kullanılan 5. amaç fonksiyonu (Z_5) MSE/+NSE'dir. Burada [Denklem \(10\)](#)'da gösterildiği şekilde NSE değerinin pozitif çıkması durumunda elde edilen NSE değeri kullanılır. $NSE \leq 0$ durumu meydana gelmişse NSE değeri 1×10^{-11} gibi oldukça düşük bir değer olarak kabul edilir. Bu sayede MSE/+NSE değeri şiddetli bir şekilde artırılmış olur. Optimizasyon algoritması minimizasyon yapacak şekilde tasarlandığında bu yolla NSE'nin negatif değer ürettiği çözümler elimine edilmiş olmaktadır.


$$Z_5 = \frac{MSE(y_g, y_m)}{+NSE(y_g, y_m)} \quad \begin{cases} +NSE = NSE & NSE > 0 \\ +NSE = 1 \times 10^{-11} & NSE \leq 0 \end{cases} \quad (10)$$

Çalışmada kullanılan son amaç fonksiyonu (Z_6) Yanlılık Yüzdesi (PBIAS)'dir [\[27\]](#). [Denklem \(11\)](#)'de gösterilen PBIAS değerinin mutlak değerce 0'a yakın olması amaçlanır. Bu değer negatif çıkması model sonucu elde edilen değerlerin gözlenmiş değerlerden yüksek olduğu, tersi ise düşük olduğunu gösterir.

$$Z_6 = PBIAS(y_g, y_m) = \left[\frac{\sum(y_g - y_m) \cdot 100}{\sum y_g} \right] \quad (11)$$

Bütün optimizasyon algoritmaları gibi YAK yöntemi de amaç fonksiyonlarını kullanarak bulduğu sonuçları iyileştirmeye çalışır. Dolayısıyla mevcut çalışmada kullanılan Z_1 (R^2) ve Z_2 (NSE) amaç fonksiyonları maksimize edildiğinde; Z_3 (MSE), Z_4 (MSE/ R^2), Z_5 (MSE/+NSE) ve Z_6 (PBIAS) amaç fonksiyonları ise minimize edildiğinde daha başarılı sonuçların elde edilmesi beklenir. Fakat, bazı durumlarda performans metrikleri kullanıcıları yanıltıcı yorumlara götürebilir. Örnek olarak aşağıda [Şekil 3](#)'te rastgele değerlerle oluşturulmuş gözlem verilerine karşılık yine rastgele üretilmiş 4 farklı modele ait zaman serisi grafiği gösterilmiştir. [Şekil 3](#)'te verilen modellere ait hesaplanan performans metrikleri ise [Tablo 2](#)'de verilmiştir. [Şekil 3](#) ve [Tablo 2](#) birlikte incelendiğinde en

dikkat çekici sonuç Model3'te gözlemlenmiştir. Bütün performans metriklerine göre en başarılı sonuca her ne kadar Model3 ulaşmış olsa da Şekil 3'teki zaman serisi grafiğinde görüldüğü gibi Model3 gözlenmiş verileri yakalamada başarılı olamamıştır. Diğer taraftan her ne kadar Model1 ve Model2'ye ait R^2 değerleri 1 olarak elde edilmiş olsa da Model1'de yüksek tahmin (overestimation) ve Model2'de ise düşük tahmin (underestimation) meydana gelmiş ve gözlenen verilere kıyasla yüksek hata değerleri elde edilmiştir. PBIAS değerlerinden de bu durum açıkça anlaşılmaktadır. Model4 ise Model1 ve Model2'ye kıyasla oldukça başarılı bir PBIAS değeri elde etmiş olsa da çok düşük bir R^2 değeri ile oldukça başarısız bir modelleme gerçekleştirmiştir.



Şekil 3. Farklı modellere ait zaman serisi grafikleri

Optimizasyon algoritmaları her ne kadar farklı şekillerde tasarlanıyor olsalar da kullanıcının gösterdiği hedef doğrultusunda en iyiyi bulmaya yönelik çalışan yöntemlerdir. Dolayısıyla performans metriklerinin doğru seçimi verilen örnekte olduğu gibi yüksek derecede önem arz etmektedir.

Tablo 2. Şekil 3'te gösterilen modellere ait performans metrikleri

Model	R^2	NSE	MSE	PBIAS
1	1,0000	-47,45	25,00	-50,06
2	1,0000	-47,45	25,00	50,06
3	1,0000	-3,00	2,06	-0,22
4	0,0022	-19,88	10,77	-1,73

3 Bulgular ve tartışma


Farklı performans metriklerinin B modellemesindeki başarısının araştırıldığı bu çalışmada, YAK optimizasyon algoritması yardımıyla Anamur'da bulunan 17320 numaralı meteoroloji gözlem istasyonundan elde edilen veriler kullanılarak B modellemesi gerçekleştirilmiştir. Yapılan çalışmalarda Denklem (5)'te gösterildiği şekilde B modelleri lineer bir biçimde kurulmuştur. Verilerin eğitime ve test gruplarına ayrılmasıyla ilgili literatürde kesin bir kural mevcut olmamakla birlikte genellikle verilerin %70-90'lık kısmı eğitime için kullanılmaktadır [28]. Bu doğrultuda eğitime-test grubu olarak %70-%30 ağırlığının yıl sayısı

bakımından sağlanması amacıyla toplam 16 yıllık veri setinin 2004-2015 yılları arasını kapsayan 11 yıllık kısmı eğitime aşamasında, kalan kısmı ise test aşamasında kullanılmıştır. Bu doğrultuda toplamda 192 adet aylık verinin ilk 132 aylık kısmı (%68) eğitime grubunu kalan 60 aylık kısmı (%32) ise test grubunu oluşturmaktadır.

YAK optimizasyon algoritmasında arı sayısı 8 olarak belirlenerek problem 5 boyutlu olacak şekilde tasarlanmıştır. Arama uzayının alt ve üst limiti $[x_j^{\min}; x_j^{\max}]$ [-5; +5] olarak seçilmiştir. Denklem (6-11)'de gösterilen amaç fonksiyonlarının performansı ne derecede etkilendiğinin daha açık bir şekilde gözlemlenebilmesi amacıyla her bir amaç fonksiyonu için YAK yöntemi 100 kere çalıştırılmış ve sonuçları kaydedilmiştir. Çalışmalardan her biri 2000 iterasyondan oluşmaktadır. Denklem (6) ve Denklem (7)'de gösterilen R^2 ve NSE değerleri için maksimizasyon, Denklem (8), Denklem (9), Denklem (10) ve Denklem (11)'de gösterilen MSE, MSE/ R^2 , MSE/+NSE ve |PBIAS| değerleri için ise minimizasyon uygulanmıştır. Her bir amaç fonksiyonu için üretilmiş 100'er adet modele ait eğitime grubu performans değerleri kutu grafiği şeklinde Şekil 4'te gösterilmiştir.

Şekil 4'te verilen bütün kutu grafikler için minimum değer (M), 1. Çeyreklik değeri (1Ç), Medyan değeri (Med), Ortalama değeri (Ort), 3. Çeyreklik değeri (3Ç) ve Maksimum değeri (Mak); R^2 , NSE, MSE ve PBIAS metriklerine göre belirlenerek her bir metriğe göre en başarılı sonucun elde edildiği toplamda 24 adet gösterge değeri oluşturulmuştur. Bu gösterge değerlerinin 10 adedinin (M NSE, 1Ç NSE, Med NSE, Ort NSE, 3Ç NSE, 1Ç MSE, Med NSE, Ort MSE, 3Ç MSE, Mak MSE) Z_5 ile, 8 adedinin (M R^2 , 1Ç R^2 , Med R^2 , Ort R^2 , 3Ç R^2 , Mak R^2 , Mak NSE, M MSE) Z_1 ile, 5 adedinin (M PBIAS, 1Ç PBIAS, Ort PBIAS, 3Ç PBIAS, Mak PBIAS) Z_6 ile ve sadece 1 adedinin (Med PBIAS) Z_3 ile elde edildiği sonucuna ulaşılmıştır. Mevcut sonuçlardan yola çıkıldığında en başarılı çözümlerin genel olarak MSE/+NSE minimizasyonu ile elde edildiği görülmektedir. MSE/+NSE minimizasyonu (Z_5) ile elde edilen çözümlerin gerek MSE minimizasyonu (Z_3) ile gerekse de NSE maksimizasyonu (Z_2) ile elde edilen çözümlerden daha başarılı olduğu görülmüştür. Z_1 ve Z_6 amaç fonksiyonları ise kendi kriterlerine göre en başarılı çözümleri elde ederken diğer kriterlerde önemli derecede bir başarıya ulaşamamıştır, Z_1 'de en yüksek R^2 değerleri elde edilirken, Z_6 'da en başarılı PBIAS değerlerine ulaşılmıştır. Z_2 , Z_3 ve Z_4 amaç fonksiyonlarının ise genel olarak kayda değer bir başarıya ulaşamadıkları söylenebilir. Sonuç olarak genel bir performans değerlendirmesi yapılacak olursa; en başarılı çözümlerlerin Z_5 ile elde edildiği, devamında Z_1 ve Z_6 'nın daha başarılı olduğu, Z_2 , Z_3 ve Z_4 'ün ise diğerlerine kıyasla daha başarısız olduğu sonucuna ulaşılmıştır.


Bu aşamadan sonra sonuçların daha detaylı bir şekilde incelenebilmesi amacıyla her bir amaç fonksiyonu ile üretilen 100'er adet model en başarılıdan en başarısızına göre sıralanmış ve en başarılı olan ilk 5 model belirlenerek değerleri kaydedilmiştir. Her bir amaç fonksiyonu ile üretilmiş en başarılı ilk 5 modele ait performans bilgileri Tablo 3'te, zaman serisi grafikleri Şekil 5'te ve Taylor grafikleri ise Şekil 6'da gösterilmiştir.




Şekil 4. Z_1 (a), Z_2 (b), Z_3 (c), Z_4 (d), Z_5 (e) ve Z_6 (f) ile üretilen modellerin eğitim performanslarına ait kutu grafikleri

Tablo 3. Çalışma sonucunda her bir amaç fonksiyon ile üretilen en başarılı ilk 5 modele ait performans bilgileri

		Eğitime				Test			
		R ²	NSE	MSE	PBIAS	R ²	NSE	MSE	PBIAS
Z ₁	y _{m1} (1)	0.771	-0.348	3447.211	42.682	0.955	-0.181	4572.293	44.198
	y _{m2} (1)	0.769	-10.864	30339.118	131.354	0.956	-9.053	38928.866	129.928
	y _{m3} (1)	0.764	0.757	621.617	-0.652	0.956	0.900	385.423	7.376
	y _{m4} (1)	0.762	0.499	1281.131	20.383	0.944	0.462	2084.493	26.918
	y _{m5} (1)	0.761	-0.238	3165.976	39.453	0.962	-0.235	4781.669	44.061
	Ortalama	0.765	-2.039	7771.011	46.644	0.954	-1.621	10150.549	50.496
Z ₂	y _{m1} (2)	0.754	0.749	641.590	2.037	0.940	0.837	629.803	11.156
	y _{m2} (2)	0.765	0.708	746.099	6.983	0.942	0.866	520.658	11.759
	y _{m3} (2)	0.744	0.703	760.559	3.741	0.929	0.853	567.362	11.593
	y _{m4} (2)	0.702	0.702	762.949	0.212	0.918	0.746	983.445	13.797
	y _{m5} (2)	0.722	0.658	875.728	-7.282	0.936	0.739	1009.294	5.506
	Ortalama	0.737	0.704	757.385	1.138	0.933	0.808	742.112	10.762
Z ₃	y _{m1} (3)	0.726	0.706	751.481	-4.821	0.951	0.821	691.631	6.231
	y _{m2} (3)	0.696	0.690	792.418	3.157	0.897	0.701	1157.905	16.009
	y _{m3} (3)	0.712	0.687	801.663	0.501	0.900	0.813	726.029	12.049
	y _{m4} (3)	0.677	0.666	854.433	3.128	0.886	0.694	1183.053	16.883
	y _{m5} (3)	0.675	0.663	861.528	4.276	0.894	0.655	1334.091	18.371
	Ortalama	0.697	0.682	812.305	1.248	0.906	0.737	1018.542	13.909
Z ₄	y _{m1} (4)	0.744	0.720	715.212	4.708	0.944	0.742	998.742	13.134
	y _{m2} (4)	0.738	0.707	749.704	5.486	0.923	0.787	824.975	15.051
	y _{m3} (4)	0.741	0.675	831.929	-7.804	0.962	0.784	835.316	4.300
	y _{m4} (4)	0.713	0.683	810.785	-4.940	0.924	0.899	390.269	1.393
	y _{m5} (4)	0.745	0.652	889.321	12.414	0.940	0.691	1196.894	18.535
	Ortalama	0.736	0.687	799.390	1.973	0.939	0.781	849.239	10.482
Z ₅	y _{m1} (5)	0.755	0.726	700.441	0.251	0.948	0.922	300.183	5.753
	y _{m2} (5)	0.733	0.720	715.766	0.109	0.927	0.840	619.651	11.163
	y _{m3} (5)	0.742	0.704	757.864	-8.083	0.956	0.890	426.957	2.860
	y _{m4} (5)	0.741	0.681	815.584	-9.746	0.945	0.844	603.347	2.903
	y _{m5} (5)	0.743	0.674	832.848	10.573	0.923	0.713	1112.133	18.551
	Ortalama	0.743	0.701	764.500	-1.379	0.940	0.842	612.454	8.246
Z ₆	y _{m1} (6)	0.486	-45.037	117724.380	0.003	0.655	-25.052	100880.821	24.003
	y _{m2} (6)	0.587	-0.989	5085.065	0.006	0.772	0.116	3422.185	13.479
	y _{m3} (6)	0.467	-54.129	140974.110	-0.022	0.620	-36.834	146502.163	14.686
	y _{m4} (6)	0.390	-92.688	239578.005	-0.077	0.543	-58.153	229058.780	-7.610
	y _{m5} (6)	0.374	-33.893	89227.331	0.084	0.520	-21.913	88725.489	2.570
	Ortalama	0.461	-45.347	118517.778	-0.001	0.622	-28.367	113717.888	9.426



Şekil 5. Z_1 (a), Z_2 (b), Z_3 (c), Z_4 (d), Z_5 (e) ve Z_6 (f) ile üretilen en başarılı ilk 5 modele ait aylık zaman serisi grafikleri



Şekil 6. Z_1 , Z_2 , Z_3 , Z_4 ve Z_5 ile üretilen en başarılı ilk 5 modele ait eğitim (a) ve test (b) gruplarına ait Taylor grafikleri

Tablo 3'te gösterilen değerlerin birbirleri arasında kıyaslanabilmesi amacıyla ortalamaları alınarak bu değerlere göre yorumlamalara gidilmiştir. Ortalama değerlere bakıldığında eğitim grubunda Z_2 ve test grubunda ise Z_5 'in daha ön plana çıktığı görülmektedir. Eğitim grubunda Z_2 hem NSE hem de MSE metriklerinde daha başarılı sonuçlara ulaşırken test grubunda Z_5 NSE, MSE ve PBIAS metriklerinde daha başarılı sonuçlar elde etmiştir. Burada dikkat çeken başka bir durum ise Z_6 'nın belirgin bir şekilde başarısız olduğudur. PBIAS minimizasyonu ile gerçekleştirilen çözümlemelerde en başarılı olarak kabul edilen ilk 5 model metrikleri bile oldukça düşük seviyede kalarak çok zayıf bir performans sergilemiştir. Bu durum Şekil 5'te gösterilen zaman serisi grafiklerinde de açıkça görülmektedir. Z_6 ile elde edilen modeller her ne kadar çok düşük PBIAS değerleri üretmiş olsalar da gözlenmiş olan

değerlere kıyasla çok yüksek hata değerleri oluşturarak çok düşük seviyede ilişki yapısı sergilemişlerdir.

Şekil 5'teki zaman serisi grafikleri incelendiğinde ilk etapta Z_6 'nın başarısız olduğu ve Z_1 'in düşük tahmin değerleri ürettiği görülmektedir. Z_1 ile üretilen modellerin oluşturduğu tahmin değerlerinin çok büyük bir kısmı gözlenmiş verilerin altında kalmaktadır. Zaman serisi grafikleri Z_2 , Z_3 , Z_4 ve Z_5 için incelendiğinde genel olarak bir trendin yakalanmış olduğu ve gözlenmiş olan verilere tatmin edici bir şekilde yakın sonuçlar üretildiği söylenebilir. Elde edilen sonuçların yine farklı bir yolla incelenebilmesi için Şekil 6'da eğitim ve test gruplarına ait Taylor grafikleri verilmiştir. Bu aşamada özellikle Z_6 'nın gerek Tablo 3 gerekse de Şekil 5'te görüldüğü gibi oldukça başarısız modeller üretmesi sebebiyle Şekil 6'daki Taylor grafiklerinde kullanılmasına gerek duyulmamıştır.

Taylor grafikleri model sonucu elde edilen noktalar ile gözlenmiş noktalar arasındaki korelasyonun ve dağılım benzerliğinin görsel bir şekilde incelenmesine imkân sağlayan diyagramlardır. **Şekil (6a)**'da verilen Taylor grafiği incelendiğinde, genel olarak Z_1 'in düşük tahmin değerleri üretirken diğer amaç fonksiyonlarına kıyasla standart sapma çizgisinin daha altında gruplaştığı görülmektedir. Buna karşılık en başarılı çözümlerin genel anlamda Z_5 ile üretilmiş olduğu ifade edilebilir. Z_5 ile elde edilen modeller diğer amaç fonksiyonlarına benzer bir korelasyon davranışı sergilemesine karşılık daha belirgin bir şekilde standart sapma eğrisine daha yakın bölgelerde gruplaşarak orijinal verilere daha yakın bir dağılım sergilemiştir. Z_3 ise ortalama olarak Z_5 e benzer bir standart sapma dağılımı göstermiş olsa da korelasyon değerleri Z_5 'e kıyasla daha düşük seviyede kalmıştır. Bunların yanında Z_2 ve Z_4 amaç fonksiyonlarının birbirine benzer bir davranış sergilediği görülmüştür. Test grubu veriler için elde edilen ve **Şekil (6b)**'de gösterilen Taylor grafiği incelendiğinde de eğitme grubuna benzer şekilde özellikle Z_1 'in düşük tahmin değerleri ürettiği ve Z_5 'in diğerlerine kıyasla gözlenmiş verilere daha yakın bir dağılım sergilediği görülmektedir. Mevcut sonuçlardan yola çıkarak farklı amaç fonksiyonları ile üretilen en başarılı ilk 5 model incelendiğinde en yüksek performansın Z_5 ile en düşük performansın ise Z_6 ile elde edildiği, bunun yanında Z_1 ile üretilen modellerin düşük tahmin değerleri elde ettiği ve son olarak kullanılan diğer amaç fonksiyonlarının birbirlerine benzer bir davranış yapısı sergiledikleri sonucuna ulaşılmıştır.

Çalışmanın son kısmında her bir amaç fonksiyonu ile elde edilen en başarılı modeller birbirleriyle kıyaslanmıştır. Bunun için öncelikle en başarılı modeller **Şekil 7**'de zaman serisi ve **Şekil 8**'de ise Taylor grafiği şeklinde sunulmuştur. Yapılan çalışmada Z_1 , Z_2 , Z_3 , Z_4 , Z_5 ve Z_6 ile üretilen en başarılı modeller sırasıyla **Denklem (12)**, **Denklem (13)**, **Denklem (14)**, **Denklem (15)**, **Denklem (16)** ve **Denklem (17)**'de gösterilmiştir.

$$y_{m1}(1) = 4.584xTS - 0.181xNN + 3.780xRH - 1.217xS - 0.048xY \quad (12)$$

$$y_{m1}(2) = 4.465xTS + 0.483xNN + 4.771xRH - 0.543xS - 0.153xY \quad (13)$$

$$y_{m1}(3) = 3.522xTS + 0.421xNN - 4.227xRH + 1.482xS + 0.004xY \quad (14)$$

$$y_{m1}(4) = 2.201xTS + 0.096xNN + 1.553xRH + 2.990xS + 0.027xY \quad (15)$$

$$y_{m1}(5) = 4.786xTS - 0.253xNN - 0.773xRH + 1.802xS - 0.028xY \quad (16)$$

$$y_{m1}(6) = 1.285xTS + 4.097xNN - 3.765xRH + 4.491xS - 3.447xY \quad (17)$$


Yapılan çalışma sonucunda her bir amaç fonksiyonu ile elde edilen ve **Denklem (12-17)**'de gösterilen modellerin eğitme ve test performansları **Tablo 3** doğrultusunda

incelendiğinde öncelikle daha önce elde edilen sonuçlara paralel olarak Z_6 'ya ait en başarılı modelin bile oldukça başarısız sonuçlar elde ettiği görülmektedir. $y_{m1}(6)$ modelinin eğitme PBIAS değeri her ne kadar 0.003 gibi oldukça düşük bir değer olarak elde edilmiş olsa da eğitme NSE değeri -45.037 olarak elde edilmiş olup MSE değeri de oldukça yüksektir. Bu durum **Şekil (7f)**'de verilen zaman serisi grafiğinde de açıkça görülmektedir.

Diğer taraftan Z_1 ile yapılan R^2 maksimizasyonundan elde edilen en başarılı model olan $y_{m1}(1)$ 'de düşük tahmin problemi meydana gelmiştir. Bu durum gerek **Şekil (7a)**'daki zaman serisi grafiğinde, gerekse de **Şekil 8**'deki Taylor diyagramlarında gözükmemektedir. $y_{m1}(6)$ modelinin eğitim (42.682) ve test (44.198) PBIAS değerlerinin de yüksek çıkmış olması bu sonucu destekler niteliktedir. Diğer amaç fonksiyonları ile elde edilen en başarılı çözümler incelendiğinde özellikle Z_5 'in ön plana çıktığı görülmüştür. Z_2 , Z_3 , Z_4 ve Z_5 'in **Tablo 3**'te gösterilen eğitim performans değerleri arasında çok fazla bir fark olmadığı fakat test değerlerinde Z_5 'in diğerlerine kıyasla daha başarılı olduğu görülmektedir. Diğer taraftan **Şekil 8**'deki Taylor grafiklerinde de $y_{m1}(5)$ modelinin diğer modellere kıyasla gözlenmiş verilere daha yakın bir dağılımla sonuç ürettiği söylenebilir.

Mevcut sonuçlardan yola çıkarak 6 farklı amaç fonksiyonu içerisinde en başarılı çözümün Z_5 ile yapılan MSE/+NSE minimizasyonu ile elde edilen $y_{m1}(5)$ modeliyle elde edildiği sonucuna ulaşılmıştır. MSE/+NSE minimizasyonu gerek grup başarısında gerek en başarılı ilk 5 model incelemesinde, gerekse de en başarılı model incelemelerinde başarısını belirgin bir şekilde göstererek mevcut veriler için en uygun amaç fonksiyonu olduğunu göstermiştir. Diğer taraftan Z_1 amaç fonksiyonu ile gerçekleştirilen R^2 maksimizasyonunda genel olarak yüksek tahmin/düşük tahmin problemleri meydana gelmiştir. Bu bakımdan her ne kadar Z_1 ile elde edilen modellerde ilişki seviyesi yüksek olarak elde edilmiş olsa da bu amaç fonksiyonunun gerçeğe yakın sonuçlar vermediği görülmüştür. Çalışmadan elde edilen bir başka sonuç ise Z_6 ile gerçekleştirilen PBIAS minimizasyonunun oldukça kötü bir performans sergilemesi olmuştur. Z_6 ile elde edilen modellerde her ne kadar çok düşük (<0.01) PBIAS değerleri elde edilmiş olsa da bu modeller gerek ilişki göstergeleri bakımından gerekse de hata metrikleri bakımından kayda değer bir sonuç elde edememişlerdir. Kullanılan diğer amaç fonksiyonları (Z_2 , Z_3 ve Z_4) ise Z_5 kadar olmasa da ortalama olarak başarılı modeller üretebileceklerini göstermişlerdir.

Son olarak YAK optimizasyon algoritmasının çözümü iyileştirme durumunun incelenebilmesi amacıyla he bir amaç fonksiyonu ile elde edilen en başarılı modellerin yakınsama grafikleri **Şekil 9**'da gösterilmiştir. Yakınsama grafikleri iterasyonlar boyunca amaç fonksiyonu ile elde edilen değerlerin değişimini gösteren grafiklerdir. **Şekil 9** incelendiğinde bütün amaç fonksiyonları için YAK optimizasyon algoritmasının başlangıçta ürettiği çözümü iyileştirdiği görülmektedir.




Şekil 7. Z_1 (a), Z_2 (b), Z_3 (c), Z_4 (d), Z_5 (e) ve Z_6 (f) ile üretilen en başarılı modellere ait aylık zaman serisi grafikleri


Mevcut çalışmada 6 farklı amaç fonksiyonu kullanılarak B modellemesi gerçekleştirilmiş olup bu amaç fonksiyonları arasında literatürde bu konuda daha önce uygulanmamış olan MSE/+NSE amaç fonksiyonu ile en başarılı çözümlerin elde edildiği görülmüştür. Bu sonucun mevcut çalışmanın ana çıktısını teşkil ettiği ve çalışmanın yenilikçi kısmını oluşturduğu düşünülmektedir. Bu aşamada literatürdeki benzer çalışmalar incelendiğinde araştırmacıların genellikle performans metriklerini sonuçların yorumlanmasında kullanmış oldukları görülmektedir. B konusunda mevcut çalışmanın paralelinde performans metriklerinin birbirleri arasında kıyaslamalı bir şekilde incelendiği bir çalışma

literatürde bulunmamaktadır. Bu bakımdan mevcut çalışmanın literatüre farklı bir yönden katkı sağlayacağı düşünülmektedir.

B konusunda literatürdeki farklı çalışmalar incelendiğinde araştırmacıların ağırlıklı olarak Kök Ortalama Kare Hatası (Root Mean Squared Error, RMSE) [3,4,29-36] ve Ortalama Mutlak Hata (Mean Absolute Error, MAE) [3,4,31,35,36] gibi hata bazlı metrikleri tercih ettikleri görülmektedir, diğer taraftan NSE [3,30-32,34,36], R^2 [31,33,36] ve Korelasyon Katsayısı (R) [3,29,30,34,36] gibi ilişki bazlı performans metriklerinin de B modellemesinde literatürde yaygın bir biçimde kullanıldığı görülmüştür.



Şekil 8. Z_1 [$y_{m1}(1)$], Z_2 [$y_{m1}(2)$], Z_3 [$y_{m1}(3)$], Z_4 [$y_{m1}(4)$] ve Z_5 [$y_{m1}(5)$] ile üretilen en başarılı modellerin eğitim (a) ve test (b) grupları için Taylor diyagramları



Şekil 9. $y_{m1}(1)$ [a], $y_{m1}(2)$ [b], $y_{m1}(3)$ [c], $y_{m1}(4)$ [d], $y_{m1}(5)$ [e] ve $y_{m1}(6)$ [f] modellerine ait yakınsama grafikleri

Mevcut çalışmanın sonuçları incelendiğinde performans metriklerinin optimizasyon algoritmalarından elde edilecek sonucu önemli derecede etkileyebileceği ve tek başına kullanımının oldukça yanıltıcı sonuçlar doğurabileceği çıktısı elde edilmiştir. Herhangi bir amaç fonksiyonu ile üretilen modeller kendi kriterlerine göre başarılı sonuçlar elde etseler de diğer kriterlerde daha kötü sonuçlara ulaşarak başarısız bir modellemeye meydan verebilmektedirler. Bu bakımdan özellikle performans metriklerinin zayıf yönleri göz önünde bulundurularak yorumlama yapılması sağlıklı bir modelleme için yüksek derecede önem arz etmektedir. Bu bağlamda özellikle PBIAS ve R^2 metriklerinin mevcut çalışma özelinde güvensiz birer metrik olduğu görülmüştür.

4 Sonuçlar

Mevcut çalışmadan elde edilen bulgular neticesinde öncelikle YAK optimizasyon algoritmasının başarılı B modelleri üretebildiği görülmüştür. Farklı amaç fonksiyonlarıyla üretilen modeller arasında en başarılı olarak kabul edilen $y_{m1}(5)$ modelinde eğitime için $0.755 R^2$, 0.726 NSE ve 0.251 PBIAS değerleri üretilirken test grubunda bu başarı R^2 , NSE ve PBIAS için sırasıyla 0.948 , 0.922 ve 5.753 olarak elde edilmiştir. Özellikle test performansının oldukça başarılı olması YAK optimizasyon algoritmasının B modellemesinde başarılı sonuçlar üretebilecek bir yöntem olduğunu kanıtlamaktadır. Diğer taraftan yakınsama grafiklerinde bütün amaç fonksiyonları için YAK yönteminin çözümü giderek iyileştirmiş olduğu görülmektedir. Buradan yola çıkarak YAK yöntemi gibi farklı optimizasyon algoritmalarıyla daha başarılı sonuçların üretilenme ihtimalinin her zaman için geçerli olduğu söylenebilir.

Özellikle PBIAS minimizasyonu ile elde edilen modellerde çok düşük PBIAS değerleri elde edilmiş olsa da ulaşılan modeller oldukça başarısız seviyede kalmıştır. Diğer taraftan R^2 maksimizasyonu ile elde edilen modellerde gözlenmiş olan verilerle model verileri arasında bir uyum yakalanmış olsa da genel olarak düşük tahmin/yüksek tahmin problemi oluşmuş ve tam anlamıyla başarılı modeller kurulamamıştır. Bu sebeplerden dolayı farklı metriklerin bir arada kullanımının modelleme sonuçlarını daha hassas ve gerçekçi bir şekilde yapılmasına yüksek seviyede fayda sağlayacağı söylenebilir. Bunlara ilave olarak özellikle Zaman serileri ve Taylor grafikleri aracılığıyla model sonuçlarının görsel bir şekilde sunulmasının da sonuçların yorumlanmasında oldukça verimli olduğu görülmüştür.

Literatürde yapılan çalışmaların büyük bir kısmında NSE metriği kullanılmış ve geçerliliğini ispatlamış bir yöntem olarak kabul edilmiştir. Mevcut çalışmada ise başta MSE/+NSE olmak üzere farklı amaç fonksiyonlarıyla da NSE maksimizasyonundan daha başarılı modellerin oluşturulabileceği görülmektedir. Bu bakımdan önerilecek daha farklı metriklerin kullanılmasıyla modelleme başarısının artırılma ihtimalinin her zaman için geçerli olduğu düşünülmektedir.

Giderek artan dünya nüfusuna karşılık sınırlı durumda bulunan su kaynaklarının daha da fazla savunmaya muhtaç hale geldiği günümüzde artık kabul edilmiş bir gerçektir. Dolayısıyla su kaynaklarının korunması ve geliştirilmesi

amacıyla buharlaşma gibi fenomenlerin yapılarının daha iyi anlaşılıp daha başarılı modellerin kurulmasıyla geleceğe yönelik daha keskin tahminlerin yapılması sağlanabilir. Bu açıdan mevcut çalışmayla birlikte bu konuda yapılan diğer çalışmaların su kaynakları mühendisliği bakımından önemli çıktılar içerdiği düşünülmektedir.

Teşekkür

Meteorolojik verilerin ölçme ve teminindeki emeklerinden ötürü MGM personeline teşekkürlerimi sunarım

Çıkar çatışması

Yazar çıkar çatışması olmadığını beyan etmektedir.

Benzerlik oranı (iThenticate): %7

Kaynaklar

- [1] F. Ellsäßer, A. Röhl, C. Stiegler, Hendrayanto and D. Hölscher, Introducing QWaterModel, a QGIS plugin for predicting evapotranspiration from land surface temperatures. Environmental Modelling & Software, 130,2020.<https://doi.org/10.1016/j.envsoft.2020.104739>.
- [2] V. P. Singh and C.-Y. Xu, Evaluation and generalization of 13 mass-transfer equations for determining free water evaporation. Hydrol Process, 11, 311–323, 1997. [https://doi.org/10.1002/\(SICI\)1099-1085\(19970315\)11:3](https://doi.org/10.1002/(SICI)1099-1085(19970315)11:3).
- [3] S. N. Qasem, S. Samadianfard, S. Kheshtgar, S. Jarhan, O. Kisi, S. Shamshirband and K. W. Chau, Modeling Monthly Pan Evaporation Using Wavelet Support Vector Regression and Wavelet Artificial Neural Networks in Arid and Humid Climates. Engineering Applications of Computational Fluid Mechanics, 13, 177–187, 2019. <https://doi.org/10.1080/19942060.2018.1564702>.
- [4] G. Tezel and M. Buyukyildiz, Monthly Evaporation Forecasting Using Artificial Neural Networks and Support Vector Machines. Theor Appl Climatol, 124, 69–80, 2016. <https://doi.org/10.1007/s00704-015-1392-3>.
- [5] Ö. Terzi, Daily Pan Evaporation Estimation Using Gene Expression Programming and Adaptive Neural-Based Fuzzy Inference System. Neural Comput Appl, 23, 1035–1044, 2013. <https://doi.org/10.1007/S00521-012-1027-X/FIGURES/9>.
- [6] J. E. Cahoon, T. A. Costello and J. A. Ferguson, Estimating Pan Evaporation Using Limited Meteorological Observations. Agric For Meteorol, 55, 191–190, 1991. [https://doi.org/10.1016/0168-1923\(91\)90061-T](https://doi.org/10.1016/0168-1923(91)90061-T).
- [7] S. Kim, J. Shiri, O. Kisi and V. P. Singh, Estimating Daily Pan Evaporation Using Different Data-Driven Methods and Lag-Time Patterns. Water Resources Management, 27, 2267–2286, 2013. <https://doi.org/10.1007/S11269-013-0287-2>.
- [8] P. B. Shirsath and A. K. Singh, A Comparative Study of Daily Pan Evaporation Estimation Using ANN, Regression and Climate Based Models. Water

- Resources Management, 24:8, 1571–1581, 2009. <https://doi.org/10.1007/S11269-009-9514-2>.
- [9] G. F. Lin, H. Y. Lin and M. C. Wu, Development of a Support-Vector-Machine-Based Model for Daily Pan Evaporation Estimation. Hydrol Process, 27, 3115–3127, 2013. <https://doi.org/10.1002/HYP.9428>.
- [10] R. M. Adnan, A. Malik, A. Kumar, K. S. Parmar and O. Kisi, Pan Evaporation Modeling by Three Different Neuro-Fuzzy Intelligent Systems Using Climatic Inputs. Arabian Journal of Geosciences, 12, 1-14, 2019. <https://doi.org/10.1007/S12517-019-4781-6/TABLES/7>.
- [11] A. D. Kulkarni and G. S. Anaokar, Prediction of Evaporation Loss in Reservoir with Fuzzy Logic Approach. European Journal of Advances in Engineering and Technology, 3, 39-42, 2016. <https://doi.org/10.13140/RG.2.2.24931.96804>.
- [12] A. Ashrafzadeh, M. A. Ghorbani, S. M. Biazar and Z. M. Yaseen, Evaporation Process Modelling over Northern Iran: Application of an Integrative Data-Intelligence Model with the Krill Herd Optimization Algorithm. Hydrological Sciences Journal, 64, 1843-1856, 2019. <https://doi.org/10.1080/02626667.2019.1676428>.
- [13] M. A. Ghorbani, R. Kazempour, K. W. Chau, S. Shamshirband and P. T. Ghazvinei, Forecasting Pan Evaporation with an Integrated Artificial Neural Network Quantum-Behaved Particle Swarm Optimization Model: A Case Study in Talesh, Northern Iran. Engineering Applications of Computational Fluid Mechanics, 12(1), 724-737, 2018. <https://doi.org/10.1080/19942060.2018.1517052>.
- [14] A. R. Ghumman, Y. M. Ghazaw, A. Alodah, A. ur Rauf, M. Shafiquzzaman and H. Haider, Identification of Parameters of Evaporation Equations Using an Optimization Technique Based on Pan Evaporation. Water, 12, 2020. <https://doi.org/10.3390/W12010228>.
- [15] S. Kim and H. S. Kim, Neural Networks and Genetic Algorithm Approach for Nonlinear Evaporation and Evapotranspiration Modeling. J Hydrol (Amst), 351, 299–317, 2008. <https://doi.org/10.1016/J.JHYDROL.2007.12.014>.
- [16] L. Wang, O. Kisi, M. Zounemat-Kermani and H. Li, Pan Evaporation Modeling Using Six Different Heuristic Computing Methods in Different Climates of China. J Hydrol (Amst), 544, 407–427, 2017. <https://doi.org/10.1016/J.JHYDROL.2016.11.059>.
- [17] M. Bulmer, Principles of Statistics. Courier Corporation, 1979.
- [18] B. G. Tabachnick, L. S. Fidell and J. B. Ullman, Using multivariate statistics (Seventh), 2019.
- [19] D. Karaboga, An idea based on honey bee swarm for numerical optimization, Erciyes university, engineering faculty, computer engineering department. Technical report-tr06, 2005.
- [20] D. Karaboga and B. Akay, A Comparative Study of Artificial Bee Colony Algorithm. Appl Math Comput, 213, 108-132, 2009. <https://doi.org/10.1016/J.AMC.2009.03.090>.
- [21] A. L. Bolaji, A. F. Bamigbola, L. B. Adewole, P. B. Shola, A. Afolorunso, A. A. Obayomi, D. R. Aremu and A. A. A. Almazroi, A Room-Oriented Artificial Bee Colony Algorithm for Optimizing the Patient Admission Scheduling Problem. Comput Biol Med, 148, 2022. <https://doi.org/10.1016/J.COMPBIOMED.2022.105850>.
- [22] Y. Cui, W. Hu and A. Rahmani, A Reinforcement Learning Based Artificial Bee Colony Algorithm with Application in Robot Path Planning. Expert Syst Appl, 203, 2022. <https://doi.org/10.1016/J.ESWA.2022.117389>.
- [23] V. Yılmaz, The Use of Band Similarity in Urban Water Demand Forecasting as a New Method. Water Supply, 22, 1004-1019, 2022. <https://doi.org/10.2166/WS.2021.221>.
- [24] M. W. Van Liew, T. L. Veith, D. D. Bosch and J. G. Arnold, Suitability of SWAT for the conservation effects assessment project: a comparison on USDA-ARS experimental watersheds, J. Hydrol. Eng., 12 (2), 173-189, 2007. [https://doi.org/10.1061/\(ASCE\)1084-0699\(2007\)12:2\(173\)](https://doi.org/10.1061/(ASCE)1084-0699(2007)12:2(173)).
- [25] J. E. Nash and J. v. Sutcliffe, River Flow Forecasting through Conceptual Models Part I — A Discussion of Principles. J Hydrol (Amst), 10, 282-290, 1970. [https://doi.org/10.1016/0022-1694\(70\)90255-6](https://doi.org/10.1016/0022-1694(70)90255-6).
- [26] D. N. Moriasi, J. G. Arnold, M. W. Van Liew, R. L. Bingner, R. D. Harmel and T. L. Veith, Model Evaluation Guidelines for Systematic Quantification of Accuracy in Watershed Simulations. Trans ASABE, 50, 885-900, 2007. <https://doi.org/10.13031/2013.23153>.
- [27] H. V. Gupta, S. Sorooshian and P. O. Yapo, Status of automatic calibration for hydrologic models: Comparison with multilevel expert calibration. Journal of hydrologic engineering, 4(2), 135-143, 1999. [https://doi.org/10.1061/\(ASCE\)10840699\(1999\)4:2\(135\)](https://doi.org/10.1061/(ASCE)10840699(1999)4:2(135)).
- [28] M. Buyukyildiz and S. Y. Kumcu, An Estimation of the Suspended Sediment Load Using Adaptive Network Based Fuzzy Inference System, Support Vector Machine and Artificial Neural Network Models. Water Resources Management, 31, 1343-1359, 2017. <https://doi.org/10.1007/s11269-017-1581-1>.
- [29] M. K. Goyal, B. Bharti, J. Quilty, J. Adamowski and A. Pandey, Modeling of daily pan evaporation in sub tropical climates using ANN, LS-SVR, Fuzzy Logic, and ANFIS, Expert Systems with Applications, 41, 5267-5276, 2014. <https://doi.org/10.1016/J.ESWA.2014.02.047>.
- [30] A. Ashrafzadeh, A. Malik, V. Jothiprakash, M. A. Ghorbani and S. M. Biazar, Estimation of daily pan evaporation using neural networks and meta-heuristic approaches, ISH Journal of Hydraulic Engineering, 26:4, 421-429, 2020. <https://doi.org/10.1080/09715010.2018.1498754>.

- [31] Z. M. Yaseen, A. M. Al-Juboori, U. Beyaztas, N. Al-Ansari, K. W. Chau, C. Qi, M. Ali, S. Q. Salih and S. Shahid, Prediction of evaporation in arid and semi-arid regions: a comparative study using different machine learning models. *Engineering Applications of Computational Fluid Mechanics*, 14(1), 70-89, 2020. <https://doi.org/10.1080/19942060.2019.1680576>.
- [32] A. Malik, A. Kumar, S. Kim, M. H. Kashani, V. Karimi, A. Sharafati, M. A. Ghorbani, N. Al-Ansari, S. Q. Salih, Z. M. Yaseen and K. W. Chau, Modeling monthly pan evaporation process over the Indian central Himalayas: application of multiple learning artificial intelligence model. *Engineering Applications of Computational Fluid Mechanics*, 14(1), 323-338, 2020. <https://doi.org/10.1080/19942060.2020.1715845>.
- [33] R. Moazenzadeh, B. Mohammadi, S. Shamshirband and K. W. Chau, Coupling a firefly algorithm with support vector regression to predict evaporation in northern Iran, *Engineering Applications of Computational Fluid Mechanics*, 12(1), 584-597, 2018. <https://doi.org/10.1080/19942060.2018.1482476>.
- [34] M. Shimi, M. Najjarchi, K. Khalili, E. Hezavei and S. M. Mirhoseyni, Investigation of the accuracy of linear and nonlinear time series models in modeling and forecasting of pan evaporation in IRAN. *Arabian Journal of Geosciences*, 13, 1-16, 2020. <https://doi.org/10.1007/s12517-019-5031-7>.
- [35] S. Yang, S. Liu, X. Li, Y. Zhong, X. He and C. Wu, The short-term forecasting of evaporation duct height (EDH) based on ARIMA model. *Multimedia Tools and Applications*, 76, 24903-24916, 2017. <https://doi.org/10.1007/s11042-016-4143-2>.
- [36] L. Wu, G. Huang, J. Fan, X. Ma, H. Zhou and W. Zeng, Hybrid extreme learning machine with meta-heuristic algorithms for monthly pan evaporation prediction. *Computers and electronics in agriculture*, 168, 105-115, 2020. <https://doi.org/10.1016/j.compag.2019.105115>.

