

YİNELLENEN SİNİR AĞI MİMARİLERİ VE ZAMAN GECİKMELİ SİNİR AĞLARI KULLANARAK ZAMAN SERİSİ ÖNGÖRÜSÜ

Umut Konur
Haliç Üniversitesi Bilgisayar Mühendisliği Bölümü
umutkonur@halic.edu.tr

Ali Okatan
Haliç Üniversitesi Bilgisayar Mühendisliği Bölümü
aokatan@halic.edu.tr

Özetçe:

Bu çalışmada, yinelenen sinir ağı (YSA) mimarileri ve zaman gecikmeli sinir ağları (ZGSA) yaklaşımı birlikte kullanılarak zaman serisi öngörüsü yapılmıştır. Zaman serisi öngörüsü problemi şu biçimde ifade edilebilir: Belirli bir varlığın artan zaman anları 1, 2,t'de gözlemlenen bir gerçekleşme tarihi x_1, x_2, \dots, x_t , verildiği zaman, varlığın t+1 anındaki gerçekleşme değerini bulmak. Eğer x_i gerçel sayıysa, zaman serisi öngörme probleminin regresyon problemi olma niteliği ortaya çıkar ve zaman serisinin yakın tarihinin varlığın yeni değerinin belirlenmesinde önemli bir rol oynadığı koşuluyla tahmin edilen çözüm $\sim x_{t+1} = f(x_t, x_{t-1}, \dots, x_{t-p})$ biçiminde ifade edilebilir.

İkisi de yinelenen nitelikte olan iki sinir ağı mimarisi özel bir zaman serisi öngörme probleminde uygulanmış ve test edilmiştir. Problem, geçmişte gözlenen son birkaç değer verildiği zaman, belirli dövizlere ait çapraz kurların ertesi günkü değerini öngörme ile ilgilidir. Uygulamalar Türkiye'de gerçekleşen beş farklı kur için test edilmiş ve başarıları karşılaştırılmıştır. Ağları eğitmekte kullanılan örnek veri TCMB (Türkiye Cumhuriyeti Merkez Bankası) arşivlerinden sağlanmıştır.

Anahtar sözcükler: Zaman serisi öngörme, yinelenen sinir ağları, zaman gecikmeli sinir ağları

1. GİRİŞ

Zaman serisi öngörme; sinyal işleme, turbülans ve güneş akışı modelleme gibi çeşitli alanlarda karşılaşılan bir problemdir [1]. Öngörü ekonomide de değerli bir araçtır. Hisse senedi fiyatlarının öngörülmesi böyle bir uygulamadır. Doğru zaman serileri elde etmek, özellikle böyle serilerde var olan yüksek miktardaki gürültü nedeniyle zor bir iştir ve önu açık bir araştırma alanıdır.

Tek bir değişken için modellenen zaman serisi öngörme, regresyon fonksiyonun ilgililenen varlığın bir sonraki tahmini gerçekleşme değerini döndürdüğü bir problemdir. Bir sonraki örneğin değerinin yakın tarihe kuvvetle bağlı olması koşuluyla, regresyon fonksiyonuna sağlanan girdi varlığın son birkaç değerinden oluşur.

Bu çalışmada, yinelenen sinir ağı mimarileri ve zaman gecikmeli sinir ağı yaklaşımı özel bir probleme uygulanmıştır, bu belirli bir döviz cinsine ait ertesi gün gerçekleşmesi beklenen çapraz kurun tahmin edilmesi problemdir.

Zaman serisi öngörücüsü olarak rol alan bir ZGSA'nın eğitimi sabit boyutlu bir kayan pencereye girdi beslemek, bir çıktı elde etmek ve ağ ağırlıklarında uygun değişiklikleri yapmak biçiminde başarılmaktadır. Bu süreç zaman penceresi günümüze daha yakın olan bir adım öteye konumlandırıldıktan sonra tekrar eder. Eğitim, günümüze kadar var olan bütün veri kullanıldıktan ve ağ ağırlıkları elde edildikten sonra sona ermektedir.

Zaman penceresinin sabit boyutu çoğu zaman sınırlayıcı olmaktadır. Zaman penceresinin çok dar olması durumunda önemli ipuçları kenarda kalabilirken, geniş olması durumunda da yetersiz girdiler gürültü olarak algılanır. İdeal olanı zaman

penceresinin boyutunu çerçeveye uydurmaktır. Bunu başarmanın bir yolu yinelenen sinir ağlarını (YSA) kullanmaktır. YSA'lar iç durumlarında geçmişle ilgili bilgileri tutmak üzere eğitilebilirler ve böylece öngörü yaparken değişken uzunlukta bir tarihi dikkate alabilirler [2].

Çalışmada, ifade edilen fikirleri uygulayarak ve TCMB (Türkiye Cumhuriyeti Merkez Bankası)' den elde edilen verileri kullanarak sinir ağlarını eğittikten sonra çapraz kurlar için zaman serisi öngörüsü yapılmaktadır. Gerçekte, çapraz kur verisine ait zaman serisi öngörüsü gürültülü bir zaman serisi öngörüsüdür ve elde edilen sonuçlar daha az gürültünün olduğu ve daha belirli davranan varlıkları öngörmede elde edilen sonuçlar kadar tatmin edici olmayabilir. Literatürde, Giles, Lawrence ve Tsoi yinelenen bir sinir ağı ve dilbilgisel çıkarım kullanarak gürültülü zaman serisi öngörmeye ilişkin bir fikir önermektedirler [3]. [3]'teki öngörme algoritması bu çalışmada olduğu gibi çapraz kurlara uygulanmakta ve yöntem bir sonraki iş günü için kurun değişme yönünü öngörmek biçiminde çalışmaktadır. Yani, o çalışmada ilgililenen problem bir regresyon problemine eşdeğer değildir. Öngörülen değişim yönünün pozitif, negatif veya sıfır olacağıdır. Önerilen yöntem bir kendini düzenleyen harita ve YSA yardımıyla yapılan dilbilgisel çıkarımı kullanarak işaretel temsile dönüşümden yararlanmaktadır. Daha sonra, eğitilen YSA lardan işaretel bilgi işaretel temsil yardımıyla belirleyici sonlu durum makineleri olarak çıkarılmaktadır.

[3]'teki yöntem %47.1 ile %40 arasında hata oranları bildirmekte ve bu oranlar değişim yönü öngörüsünde ve ekonomik bağlamda tatmin edici bulunmaktadır Bu noktada, gürültülü zaman serisi

öngörüsünün zor bir iş olduğu ortaya çıkmakta ve sembolik sonuç öngörüsünün dahi çok hata ürettiği görülmektedir.

2. GERÇEKLENME

Kullanılan zaman serisi verisi:

İlk bölümde belirtildiği üzere, zaman serisi verisi TCMB'nin web sitesinden elde edilebilir. Veri bankanın her iş gününün sonunda bir sonraki iş günü için duyurduğu çapraz kurlarla ilgilidir. Bu çalışmada yapılan deneylerde Amerikan Doları/Avustralya Doları (AD), Amerikan Doları/Kanada Doları (CD), Amerikan Doları/İsviçre Frangı (SF), İngiliz Sterlini/Amerikan Doları (BP) ve Amerikan Doları/Japon Yeni (JY) kurları dikkate alınmıştır.

Kullanılan veri 01/05/1981 ile 31/05/2004 tarihleri arasında her iş günü için gözlemlenen günlük çapraz kurlardan oluşmaktadır. Her bir çapraz kur için kullanılan veri noktası sayısı 5824'tür. Bunlardan ilk 5817 tanesi eğitimde, son 7 tanesi de öngörücülerin doğruluğunu test etmek amacıyla kullanılmaktadır.


Gerçeklenen ağ mimarileri:

Uygulamada, iki tür yinelenen sinir ağı (ve ayrıca ZGSA) gerçekleştirilmesi bulunmaktadır. Bunlar sırasıyla *tür 1* ve *tür 2* olarak anılacaktır. Kullanılan bütün ağ mimarilerinde, gerçek girdinin boyutu 6dır. Yani zaman penceresinin boyu 6dır. Ayrıca, mimarilerdeki saklı düğümlerin sayısı 8dir. Hem girdi katmanı hem de saklı katman ön yargıya sahiptirler. Aşağıda iki tür ağ mimarisinin tarifleri verilmektedir:


Tür 1: Bu türdeki ağda, saklı birimlerin çıktıları tüm saklı birimlere girdi olarak geri beslenmektedir. Böylelikle etkin girdinin boyutu 14 olmaktadır. Söz konusu mimari değişmiş bir Elman ağı gibi algılanabilir.

Tür 2: Bu tür ağda, ağı son çıktısı tüm saklı birimlere girdi olarak geri beslenmektedir. Etkin girdi boyutu 7dir.

Şekil 2.1 ve 2.2 iki farklı mimariyi göstermektedir.



Şekil 2.1 Tür 1 ağ mimarisi.



Şekil 2.2 Tür 2 ağ mimarisi

Eğitim verisi nasıl kullanıldı:

Erişilebilir eğitim verisi iki ayrı şekilde kullanılmıştır. İlki veriyi hiçbir ön işleme olmadan kullanılmaktadır. Bütün veri ağa gözlemlendiği ve kaydedildiği şekilde girilmektedir. Bu tür veriye *gerçek* veya *orijinal* veri adı verilecektir. İkinci tür kullanımda ise veri kullanılmadan önce işlenmektedir. Ön işleme kullanımdan önce var olan gürültüyü elemek için basit bir sezgisel kullanılmaktadır. Buradaki amaç daha iyi öngörü sonuçları elde etmektir. Bu tür veriye *gürültüsüz* veri denecektir.

Gürültü eleme sezgiseli basittir. Ardı ardına gelen iki zaman serisi verisi arasındaki mutlak fark bu farkların en büyüğünün yarısı olarak tanımlanan bir gürültü eşliğinden fazlaysa, gürültü yakalandığına karar verilir. Böyle bir durumda, günümüze bir adım daha yakın olan veri noktasının değeri gözlenir ve mutlak farkın eşığı aştığı saptanan veri noktası gözlenen değerle kendisinden bir adım önce gelen değerlerin ortası olarak güncellenir. Bu yöntem veri kümesinin başından sonuna kadar çalışır ve ardı ardına gelen gürültü aralıkları varsa, tüm bu aralıklar gürültüden arındırılır.

Normalizasyon çarpanları:

Uygulamada kullanılan beş değişik veri kümesi aynı ölçekte değildir. Örneğin İngiliz Sterlini/Amerikan Doları verisi 1.7 veya 2 gibi elemanlar içerirken, Amerikan Doları/Japon Yeni verisi 150, 200 ve benzeri elemanlar içermektedir. Bu durum bütün veri kümelerini aynı ölçüğe getirmek için bir normalizasyon gerektirmektedir. Söz konusu normalizasyonun amacı eğitim ve öngörü için kritik değildir ve dolayısıyla bu bağlamlarda kullanılmamaktadır. Ancak regresyon hatalarının bildiriminde rol önem kazanmaktadır. Veri değerleri aynı ölçüğe taşınmazsa karşılaştırma imkansızlaşır.

Normalizasyon çarpanlarının belirlenmesi şöyledir: Bütün veri kümesi baştan sona taranır ve en büyük eleman bulunur. Normalizasyon çarpanı en büyük elemanla çarpıldığı zaman 1 sonucunu üreten sayı olarak hesaplanır. Bu sayı en büyük elemanın çarpmaya göre tersidir.

Eğitim:

Çalışmadaki sınır ağlarının eğitimi klasik geri-yayılma ve gradyan azaltma algoritmaları ile başarılmaktadır. Bütün ağırlıkların ilklenmesi rasgeledir. Öğrenme ve test kümeleri önceden belirtildiği gibidir. Eğitim sürecinde momentum kullanılmaktadır. İlk öğrenme oranı 0.1 iken her eğitim örneğinin varışında $0.1/15000 = 0.0000066$ miktarı kadar azalır.

3. DENEYLER VE SONUÇLAR:

Bu bölümde, çalışmamızda uygulanan bütün öğrenciler ile yapılan deneylerin sonuçları sunulmaktadır. Öğrenme algoritması iki farklı mimari ve her bir mimari için gerçek ve gürültüsüz veriler ile çalıştırılmıştır. Böylelikle Amerikan Doları/Avustralya Doları, Amerikan Doları/Kanada Doları, Amerikan Doları/İsviçre Frangı, İngiliz Sterlini /Amerikan Doları ve Amerikan Doları / Japon Yeni öngörülerinin her biri için dört farklı sonuç kümesi elde edilmiştir. Bu bölümdeki gösterimlerde, sözü edilenler sırasıyla AD, CD, SF, BP ve JY ile ifade edilecektir.

Algoritma, her bir durum için ortalama sonuçlar elde etmek ve rasgelelikten kaynaklanan dalgalanma eğilimini elemek amacıyla 10 kere koşulmuştur. Öngörü sonuçları öğrenme kümesindeki verileri izleyen 7 iş günü için verilmektedir. Öngörülerin yapılış biçimi öyledir ki, ilk günün sonuçları en son altı öğrenim kümesi elemanı kullanılarak elde edilmekte, ikinci günün sonuçları en son beş öğrenme kümesi elemanı ve ilk günün öngörüsü kullanılarak elde edilmektedir. Üçüncü ve sonraki günler için zaman penceresi bu şekilde kaymaktadır.

Aşağıda bildirilen hata oranları test kümesine ait regresyon hataları ve yanlış değişim yönü tahminleri ile (Çapraz kur bir önceki güne göre arttı mı azaldı mı?) ilgilidir.

Öngörüler:

Tablo 3.1 - 3.5 (her bir çapraz kur için) her bir mimari-veri bileşimi için algoritmanın ilk çalışmasının eğitim kümesindeki verileri takip eden 7 güne ait öngörülerini listelemektedir.

AD Öngörüler	Gün1	Gün2	Gün3	Gün4	Gün5	Gün6	Gün7
Tür1 Orijinal	1.4377	1.4378	1.4378	1.4377	1.4376	1.4376	1.4375
Tür1 Gürültüsüz	1.4375	1.4376	1.4376	1.4375	1.4374	1.4374	1.4373
Tür2 Orijinal	1.4376	1.4378	1.4378	1.4377	1.4376	1.4376	1.4375
Tür2 Gürültüsüz	1.4375	1.4377	1.4376	1.4375	1.4375	1.4374	1.4373

Tablo 3.1 AD Öngörüler

CD Öngörüler	Gün1	Gün2	Gün3	Gün4	Gün5	Gün6	Gün7
Tür1 Orijinal	1.3856	1.3856	1.3856	1.3856	1.3855	1.3856	1.3855
Tür1 Gürültüsüz	1.3856	1.3855	1.3856	1.3855	1.3855	1.3855	1.3854
Tür2 Orijinal	1.3856	1.3856	1.3856	1.3856	1.3855	1.3856	1.3855
Tür2 Gürültüsüz	1.3856	1.3857	1.3856	1.3856	1.3855	1.3856	1.3855

Tablo 3.2 CD Öngörüler

SF Öngörüler	Gün1	Gün2	Gün3	Gün4	Gün5	Gün6	Gün7
Tür1 Orijinal	1.2898	1.2898	1.2897	1.2897	1.2896	1.2897	1.2897
Tür1 Gürültüsüz	1.2898	1.2897	1.2897	1.2897	1.2896	1.2897	1.2897
Tür2 Orijinal	1.2898	1.2897	1.2897	1.2896	1.2895	1.2896	1.2897
Tür2 Gürültüsüz	1.2898	1.2897	1.2897	1.2896	1.2896	1.2897	1.2897

Tablo 3.3 SF Öngörüler

BP Öngörüler	Gün1	Gün2	Gün3	Gün4	Gün5	Gün6	Gün7
Tür1 Orijinal	1.7671	1.7671	1.7671	1.7671	1.7673	1.7673	1.7673
Tür1 Gürültüsüz	1.7671	1.7671	1.7671	1.7671	1.7673	1.7673	1.7673
Tür2 Orijinal	1.7670	1.7671	1.7671	1.7671	1.7673	1.7673	1.7673
Tür2 Gürültüsüz	1.7671	1.7671	1.7671	1.7672	1.7673	1.7673	1.7673

Tablo 3.4 BP Öngörüler

JY Öngörüler	Gün1	Gün2	Gün3	Gün4	Gün5	Gün6	Gün7
Tür1 Orijinal	112.8578	112.8578	112.8578	112.8578	112.8578	112.8578	112.8578
Tür1 Gürültüsüz	113.5171	113.5171	113.5171	113.5171	113.5171	113.5171	113.5171
Tür2 Orijinal	113.4314	113.4314	113.4314	113.4314	113.4314	113.4314	113.4314
Tür2 Gürültüsüz	113.4314	113.4314	113.4314	113.4314	113.4314	113.4314	113.4314

Tablo 3.5 JY Öngörüler

Ortalama regresyon hataları ve yanlış değişim yönü öngörüler:

Aşağıdaki iki tablo (Tablo 3.6 ve 3.7) deneylerde elde edilen ortalama regresyon hatalarını ve yanlış değişim yönü öngörülerini listelemektedir. Ortalamalar sonuçların toplamının 10'a bölünmesi ile elde edilmiştir.

Ortalama Regresyon Hataları	AD	CD	SF	BP	JY
Tür 1 Orijinal	0.1276	0.1103	0.0544	0.4011	0.0305
Tür 1 Gürültüsüz	0.1276	0.1100	0.0544	0.4010	0.0320
Tür 2 Orijinal	0.1282	0.1108	0.0545	0.4016	0.0340
Tür 2 Gürültüsüz	0.1275	0.1106	0.0545	0.4016	0.0318

Tablo 3.6 Ortalama regresyon hataları

Ortalama Yanlış Değişim Yönlere	AD	CD	SF	BP	JY
Tür 1 Orijinal	0.6000	1.8000	3.0000	2.2000	0.9000
Tür 1 Gürültüsüz	1.1000	1.2000	2.9000	1.9000	0.7000
Tür 2 Orijinal	1.9000	2.9000	2.9000	2.4000	0.7000
Tür 2 Gürültüsüz	1.6000	2.6000	3.1000	1.5000	0.6000

Tablo 3.7 Ortalama yanlış değişim yönü öngörülleri

KAYNAKLAR

[1] d' Acierno A., Palma S., Ripullone W., *FIR NNs and Time Series Prediction: Applications to Stock Market Forecasting*, WIRN 96

[2] Assad M., Boné R., *Improving Time Series Prediction by Recurrent Neural Network Ensembles*, Université François-Rabelais, Tours 2003, pp. 1-4.

[3] Giles C., Lawrence S., Tsoi A., *Noisy Time Series Prediction using a Recurrent Neural Network and Grammatical Inference*, Machine Learning, Vol. 44, No. 12, p. 161-183, July/August 2001

4. SONUÇ:

Bir önceki bölümde sunulan sonuçlar tür 1 öngörücünün gerçek veya gürültüsüz veri ile çalışması arasında önemli bir başarı (ortalama regresyon hataları temel alınmak suretiyle) farkının olmadığını göstermektedir. Tür 2 mimarilerde, gürültüsüz veri gerçek veriden biraz daha başarılı olmuştur. Sonuçlar tür 1 veya tür 2 mimariler arasında iyi olanı seçmek için bir ölçüt ortaya koymamaktadır.

Tür 2 mimariler bir sonraki gün için doğru değişim yönünü öngörmeye daha başarısız görünmektedir, ancak sonuç genel değildir. Öngörme sürecindeki birçok olay verinin dağılımına, gürültü olup olmadığına bağlıdır. Zaman serisinin gerçekleşmesinde ve ortaya çıkışında gürültüyü önlemenin herhangi bir yolu bulunmamaktadır.