


R İLE ENERJİ MODELLEMESİ

EZGI AVCI, MSC, PHDC





YAPAY ZEKA YONTEMLERİ



YAPAY SİNİR AĞLARI (ANN)

- İnsan beynindeki nöronların çalışma şeklinden esinlenerek yapılmış olan bir bilgi işleme ve tahmin etme yöntemidir.
- İnsan doğasındaki nöronlar, sinapsisler ve aksisler yardımı ile bilgiyi alıp işlemektedirler.
- Nörona gelen sinyal eğer belirli bir eşiğin üzerinde olursa, aksise iletilmekte ve sinir ağı çalışmaktadır.
- ANN'lar bu iletişim şeklini taklit ederek, bilgiyi işlemektedirler.



YAPAY SİNİR AĞLARI (ANN)

- Çoğu ANN benzer şekilde yapılandırılır ve transfer fonksiyonları sayesinde eş zamanlı olarak çalıştırılır.
- Bu noktada ANN'ların işleme şekli gelen bilginin ağırlıklandırılarak, belirli fonksiyonların uygulanmasından sonra, çıktı elde edilmesi şeklinde gelişmektedir.
- ANN'nin ana elemanı olan fonksiyon, matematiksel mimari tarafından şekillendirilir. Ağırlıklandırma ne kadar büyük olursa, işlenen bilginin tutarlılığı da o kadar büyük olmaktadır.
- Ağırlıklar aynı zamanda negatif değerler de alabilmektedir. Gelen bilgi üzerindeki ağırlıklandırmaya göre, elde edilen çıktı da değişmektedir.



YAPAY SİNİR AĞLARI (ANN)

Elektrik fiyat tahmini başlığı altındaki çıkış düğümü sayılarına göre sınıflandırılabilirler:

Birinci grup sadece bir çıkış düğümü içeren ve

- Bir sonraki saatin fiyatını tahmin edenler (Gonzalezi Son Roque ve Garcia-Gonzalez 2005, Mandali Senjyu ve Funabashi 2006)
- h saat sonraki fiyatı tahmin edenler (Amjady 2006, Hu ve ark. 2008, Rodriguez ve Anders 2004)
- Sonraki günün zirve fiyatını tahmin edenler (Areenkul, Senju, Toyama, Chakraborty, Yona ve Urasaki 2010)
- Sonraki günün zirve fiyat ortalamasını tahmin edenler (Guo ve Luh, Zhang ve Luh 2005)
- Ertesi günün temel yük ortalama fiyatlarını tahmin edenler (Pao 2006)

İkinci olarak daha az popüler olan grup, birkaç çıkış düğümü ve fiyat vektörü tahmini içeren (24 veya 48 düğüm), sonraki günün tüm fiyat profilini tahmin edebilen yöntemler bulunmaktadır (Yamin, Shahidehpour ve Li 2004).



YAPAY SİNİR AĞLARI (ANN)

- Ağ düğümleri (nöronlar), sinirsel girdiler ve çıktılar arasındaki bağlantıyı tahsis eder ve katmanları birbirine bağlarlar.
- Çıktılar doğrusal ya da doğrusal olmayan fonksiyonların girdileridir.
- Girdiler belki diğer ağ elemanlarının çıktıları olabilirler veya gerçekten ağın girdileri olabilirler.
- Mimari terimlere göre, ANN iki kategoride toparlanabilir:

İleri ve geri beslenen türler:

İleri beslemeli olanlar genellikle tahmin algoritmaları için kullanılmaktadırlar.

Geri beslemeli yöntemler ise örüntü tanıma ve kategorileme için kullanılmaktadırlar.



ILERI BESLEMELI SINIR AĞLARI

- En kolay ağ tipi olan tek katmanlı algılayıcı ağ, gizli bir katmanı olmayan ve doğrusal regresyona eşit olan ağdır.
- Tahminler, girdilerin doğrusal kombinasyonları ile oluşurlar.
- Ağırlıklar (denklemin katsayılarına bağlı olarak), maliyet fonksiyonunu minimize eden “öğrenme algoritmaları”, yani, ortalama karekök hatası kullanılarak seçilirler (Hyndman and Athanasopoulos, 2013).
- Gizli düğümlere orta seviye katman eklenerek, doğrusal olmayan çoklu katman algılayıcısı (MLP) elde edilmektedir.
- Bu en yaygın kullanılan ileri beslemeli ağ ailesi, katmanların içinde düzenlenmiş nöronlara sahiptir.
- Bunda, bir katmandaki düğümlerin çıktıları, diğer bir katman için girdi olabilir.



GERİ YAYILIMLI ÖĞRENİM ALGORİTMASI

- Rumelhart ve McClelland tarafından 1986 yılında geliştirilen algoritma, kullanım basitliğinden dolayı en yaygın algoritmalardan biridir.
- Algoritmaya göre, ANN'lar katmanlar halinde düzenlenmiş ve bilgiyi (sinyali) ileriye doğru gidecek şekilde işlemektedirler.
- Ancak, hataları çıkıştan girişe doğru azaltmaya çalışmaktadır.
- Her bir katmandaki ağırlıklandırma, çıkıştan elde edilen hata oranına göre, yeniden hesaplanır (bazen gizli katmanlar olabilir).
- Algoritmanın arkasındaki fikir, ANN öğrenme sürecini tamamlayana kadar, hata oranını azaltmaktır.
- Öğrenme süreci, her bir katmandaki rassal ağırlıklandırma ile başlar ve hata oranına göre ağırlıklar minimize edilir.



YİNELENEN SİNİR AĞLARI (RECURRENT NEURAL NETWORKS)

- İleri-beslemeli ağlar, girilen değerler sonucunda bir sıra değer veren değil, sadece tek bir küme çıktı değeri üreten yapılar olduklarından dolayı, statik olarak sınıflandırılmaktadırlar.
- Ayrıca hafızasızdırlar, girdiye verdikleri cevap, bir önceki durumdan bağımsızdır.
- Diğer yandan, (tekrarlayan) geri beslemeli ağlar dinamik sistemlerdir.
- Yeni bir girdi kalıbı sunulduğunda, nöron çıktıları hesaplanır.
- Geri besleme yüzünden, her nöron için girdiler geliştirilmiştir.
- Bu uygulama da, ağı yeni bir duruma sokmaktadır.

DIŐSAL DEĐIŐKENLİ DOĐRUSAL OLMAYAN OTOREGRESİF MODEL (NARX)



- NARX, daha çok zaman serilerini modellemek için kullanılan ve doğrusal olmayan bir yöntemdir.
- Buna göre NARX, şimdiki değeri, sürecin önceki değerleri ya da dışsal süreçlerin şimdiki ve önceki değerlerini kullanarak açıklamakta ve/veya tahmin etmektedir.
- Cebirsel olarak NARX modeli

$$y_t = F(y_{t-1}, y_{t-2}, y_{t-3}, \dots, u_t, u_{t-1}, \dots) + \epsilon_t$$

şeklinde ifade edilmektedir.

- Burada y_t değeri; önceki çıktı değerleri ($y_{t-1} \dots$) ve dışsal girdi değerlerinden (u_t, \dots) oluşmaktadır; ϵ_t terimi ise, hata rejimi ya da gürültü olarak adlandırılmaktadır.

Örneğin, y_t gün içi elektrik fiyatı iken, u_t o günü göstermektedir. F fonksiyonu, doğrusal olmayan bir polinomial YSA fonksiyonudur.

DIŐSAL DEĐIŐKENLİ DOĐRUSAL OLMAYAN OTOREGRESİF MODEL (NARX)



- Sharma ve Srinivasan (2013), FitzHugh-Nagumo modeli birleŐtirerek, ani yükselen fiyat davranıŐlarını taklit ederek, Elman aĐı ile sonrakini ayarlamak ve ileri besleme ANN için artıkları modellemektedir.
- Melez model, Avutralya, Ontario, İspanya ve Kaliforniya piyasalarında nokta ve aralık tahmini olarak geliştirilmiŐtir.
- FitzHugh-Nagumo modeli ise Licheroni (2012) tarafından daha önceden kullanılmıŐtır.
- Anbazhagan ve Kumarappan (2013), Elman aĐını kullanarak, İspanya'da kısa dönemli fiyat tahmini yapmıŐlardır. Çalışmada, kurulan aĐ, AR ve ARX tipi farklı elektrik fiyat tahmin modellerinden daha iyi sonuçlar vermiŐtir.
- Andalib ve Atry (2009), NARX modelini, Ontario'nun saatlik enerji fiyatlarını (HOEP), geciktirilmiş HOEP fiyatlarını ve saatlik talebin geciktirilmiş deĐerlerini dıŐsal deĐiŐken olarak kabul ederek kullanmıŐlardır. Ancak benzer bir sonuç, girdileri eski fiyatlar olan ileri beslemeli metotlarda da görülmüŐtür.



ELEKTRİK FİYATLARINI ETKİLEYEN FAKTÖRLER

Sınıfı	Girdi Değişkeni	Girdi değişkeni verisinin zaman aralığı	
C1 Piyasa karakteristikleri	(1) Geçmiş yük	f(yük); (d - m, t), m = 1, 2, 3, 4, 7, 14, 21, 28	
	(1) Sistem yük oranı, (3) İthalat/İhracat, (4) Kapasite fazlası/kısıtı	(d, t), (d, t - 1), (d - 1, t), (d - 2, t), (d - 7, t)	
	d=gün	(5) Geçmiş rezerv	(d, t - 2), (d, t - 1), (d, t)
	t=anlaşma dönemi gün sayısı	(6) Nükleer, (7) Termal, (8) Hidro, (9) Üretim kapasitesi, (10) net-bağ akışı, (11) MRR, (12) Sistemin arz kısıtları, (13) Hat limitleri	(d, t)
		(14) Geçmiş piyasa takas miktarı	(d - 1, t)
C2 Stratejik olmayan belirsizlikler	(15) Tahmini Yük	(d, t - 2), (d, t - 1), (d, t)	
	(16) Tahmini rezerv, (17) Sıcaklık, (18) Çiy noktası sıcaklığı, (19) Hava durumu, (20) Petrol fiyatı, (21) Doğal gaz fiyatı, (22) Yakıt fiyatı	(d, t)	
C3 Diğer stokastik belirsizlikler	(23) Üretim arızaları, (24) Hat durumu, (25) Hat arıza planı (26) Kısıt(Tıkanıklık) endeksi	(d, t)	
C4 Davranış endeksleri	(27) Geçmiş PTF	f(price); (d - m, t - n), m = 0, 1, 2, 3, 4, 5, 6, 7, 8, 14, 21, 28, 364 and n = 0, 1, 2, 3, 4.	
	(28) Talep esnekliği, (29) Teklif stratejileri, (30) Ani fiyat yükselişi (outlier) endeksi, (31) ID işareti	(d, t)	
C5 Geçici etkiler	(32) Anlaşma dönemi, (33) Gün türü, (34) Ay, (35) Tatil kukla, (36) Noel kukla, (37) Saat değişimi, (38) Mevsim, (39) Yaz endeksi, (40) Kış endeksi	(d, t)	



AVANTAJLARI VE DEZAVANTAJLARI

- Yapay zekâ yöntemlerinin en iyi yanı, doğrusal olmayan ve karmaşık olan veriler üzerinde çalışmayı kolaylaştırmalarıdır.
- Genelde, yapay zekâ yöntemleri, elektrik fiyatlarının tahmini ve incelenmesinde istatistiksel modellerden daha iyi sonuçlar vermektedir.
- Aynı zamanda, bu modellerin esneklikleri, en zayıf noktaları olmaktadır.
- Doğrusal olmayan ve yüksek artışlı verilerin modellenmesi, hedefsel tahminlerde iyi sonuçlar vermeyebilirler.
- Bu durum, Markov deęiştirme modelleri (switching models) ile benzemektedir yani, yüksek volatilité ve doğrusal olmayan fiyat süreçlerini incelemeye iyi olmalarına rağmen; genelde tahmin yapmada zayıf kalmaktadırlar (Bessec ve Bouabdallah 2005, Dacco ve Satchell 1999).
- Doğrusal olmayan modeller başka bir potansiyel avantaja sahiptirler: doğrusal modellere göre daha iyi aralık ve yoğunluk tahmini yapabilmektedirler. Ancak, bu durum bugüne kadar kapsamlı olarak incelenmemiştir.



AVANTAJLARI VE DEZAVANTAJLARI

- Bununla beraber, sayısal yöntemlerin olduğu havuz oldukça çeşitli ve zengin olduğundan, en uygun çözümü bulmak oldukça zordur.
- En zorlu kısım, farklı sayısal yöntemleri birbiri ile karşılaştırmaktır.
- Tahmin tutarlılığı aynı piyasa ve aynı tahmin dönemini içerse de, farklı yöntemlerin hatalarını karşılaştırmak, kalibrasyon dönemi aynı olmadıkça mümkün değildir; bu nedenle, yöntemin verimliliği konusunda, böyle bir durum oluşmadıkça kesin bir kanıya varmak mümkün olmamaktadır.
- Onun yerine, belirlenen uygulama dönemini ele alacak şekilde, belirli başlangıç koşulları (parametreler) ve belirli kalibrasyon verisini içerecek şekilde performans değerlendirmesi yapılmalıdır.
- Bu tür bir eleştiri sadece sayısal yöntemleri ile sınırlı kalmamasına rağmen, doğrusal olmamaları ve çoklu parametre özelliklerinden dolayı, bu yöntemler için özellikle doğrudur.



TÜRKİYE PTF TAHMİN MODELLERİ ANALİZLERİ

Türkiye PTF tahmin analizi çalışmaları yok denecek kadar az olup çok ciddi akademik yayın eksikliği bulunmaktadır.

Az sayıda yüksek lisans/doktora tezi ve bildiri şeklinde olan çalışmaların bulgularını özetlemek gerekirse;

- **Talası ve Hayfavi(2012)** doktora tezinde logaritması alınmış günlük ortalama PTF'yi deterministik bir fonksiyonla ile çok-faktörlü stokastik bir sürecin toplamı şeklinde ele almış ve modellemişlerdir.
- Her hangi bir dışsal değişken kullanılmamış olup, veri aralığı Aralık 2009-Haziran 2011 olup Gün Öncesi Piyasa değil Gün Öncesi Planlama dönemine ait veri kullanılmış olup şu anda ki GÖP verisi dinamiğini yansıttığı söylenemez.
- Fakat Türkiye PTF analizini stokastik yöntemler ile yapan ilk çalışma olması dolayısı ile değerli bir çalışmadır.



TÜRKİYE PTF TAHMİN MODELLERİ ANALİZLERİ

Yildirim et al.(2012)

- METU IAM doktora tezinde PTF tahminini; dinamik regresyon, CMARS ve RCMARS metotlarını kullanarak yapmaya çalışmışlardır.
- Her hangi bir dışsal değişken kullanılmamıştır.
- Eğitim (training) verisi için yalnızca bir aylık veri kullanıldığından dolayı sonuçlarının geçerliliği tartışmaya açıktır.



TÜRKİYE PTF TAHMİN MODELLERİ ANALİZLERİ

- Kölmek ve Navruz (2015) çalışmasında ise 12/2009 -11/2010 aralığını eğitime verisi olarak kullanıp ANN ve AR yöntemi ile elektrik fiyat tahmini yapmıştır.
- ANN yöntemine dışsal değişken olarak geçmiş PTF, günlük ortalama sıcaklık, tahmini ikili anlaşmalar, tahmini emre amade kapasite, gün tipi değişkenlerini almışlar fakat AR yöntemi için dışsal değişken kullanmamışlardır.
- Yazarlar (S)ARIMA yerine AR yöntemi kullanma sebeplerini, Türkiye elektrik piyasasında fiyatların durağan olmasına ve sadece AR modelini kullanan bir yapının yeterli olduğuna bağlamışlardır.
- Ancak Türkiye saatlik elektrik fiyatları incelediğinde *saatlik* fiyat serisinin durağan olmadığı ve ayrıca mevsimsellik özellikleri görüldüğü gözlenmektedir.
- Yazarlar bu iki metodun MAPE'ye göre karşılaştırılması sonucu ANN yönteminin performansının daha yüksek olduğunu savunmuşlardır.
- Bu çalışma ANN yöntemini Türkiye PTF üzerine uygulayan ilk çalışmalardan olması açısından değerlidir; fakat eğitime verisi olarak alınan verinin Gün Öncesi Planlama dönemine ait olması, sadece AR modelin ele alınması ve dışsal değişkensiz kullanılarak karşılaştırma yapılmış olmasından dolayı sonuçlarının geçerliliği tartışmaya açıktır.



TÜRKİYE PTF TAHMİN MODELLERİ ANALİZLERİ

Unlu (2012)

- yüksek lisans ODTU-IAM yüksek lisans tezinde 35 günlük veri kullanarak elektrik fiyatları ve sıcaklık arasında doğrusal ilişki olup olmadığına bakmışlardır.
- Bu tez daha çok, mevsimsellik ön-analizini vurgulayarak, sıcaklık tahmini üzerine yoğunlaşmıştır.
- Son bölümde ise yaptıkları (30 günlük) sıcaklık tahminlerini kullanarak 5 günlük fiyat tahmini yapmışlar ve sıcaklık ve fiyat arasında doğrusal model (AR ve ARX) kullanarak herhangi bir ilişki bulamamışlardır.
- Bu çalışmanın en büyük eksikliği sıcaklık ve elektrik fiyatları arasındaki doğrusal olmayan ilişkiyi göz ardı etmesi ve hiç ilişki yok sonucuna varmasıdır.
- Şimdiye kadar olan çalışmaların baz aldığı veri aralığı hem elektrik piyasasının tam olarak serbestleşmediği döneme ait olup şu andaki piyasa koşullarını ve fiyat dinamiğini yansıtmamaktadır hem de eğitime verisi olarak alınan veri aralığının kısıtlı tutulması, elektrik fiyatlarının temel özellikleri ile ilgili metodolojik varsayımsal hatalar bulunduğu için genel çıkarımlar yapmak çok zordur.



TÜRKİYE PTF TAHMİN MODELLERİ ANALİZLERİ

Ozyıldırım ve Beyazıt (2014)

- çoklu doğrusal regresyon ve radyal tabanlı fonksiyon kullanarak 2010-2013 yılları PTF'sini modellemeye çalışmışlardır.
- Radyal tabanlı fonksiyonun örneklem dışı tahmin performansının az da olsa daha iyi olduğunu göstermişlerdir.
- Saatlik veri (logaritmik dönüşüm ve entegrasyon yapmadan) kullanmışlardır.
- Açıklayıcı değişken olarak geçmiş PTF verisi; sıcaklık, sıcaklığın karesi ve saatlik, günlük, aylık, bayram kukla değişkenleri kullanmışlardır.
- Bu çalışmada yazarlar hem grafiksel olarak hem de her bir saat için betimleyici istatistikleri kullanarak; saatlerin bazı zaman aralıklarına göre kümelenme yaptığını göstermişlerdir.
- Bu bulguları bizim de baz aldığımız her bir tarife zamanına göre ayrı analiz ve tahmin yapma yaklaşımımızı desteklemektedir.



TÜRKİYE PTF TAHMİN MODELLERİ ANALİZLERİ

Bildiğimiz kadarı ile günümüz piyasa koşullarını yansıtan ilk çalışma Taysi et al.(2015) IEEE bildirisidir.

- Bu çalışmada yazarlar, sadece takvim bilgisi ve geçmiş fiyat verisini dışsal değişken olarak alıp SARIMA ve ANN yöntemlerini kullanarak elektrik fiyat tahmini yapıp, söz konusu iki metodun başarımlarını karşılaştırmışlardır.
- Sonuç olarak her iki modelin de başarımlarının birbirlerine oldukça yakın olduğunu gözlemlemişler, ancak genel ortalama hataya bakıldığında ANN modelinin daha başarılı olduğunu savunmuşlardır.
- Bu çalışmanın en büyük eksikliği ise açıklayıcı değişken olarak 1,2,3 ve 4 gecikmeli fiyat değerlerini kullanmasıdır.
- Bu durum enerji ekonomisi literatüründe sıkça belirtilmektedir ve piyasa işleyiş yapısına aykırıdır.
- Yani bu çalışmadaki fiyat tahmin modelleri gerçek hayatta kullanılamaz çünkü günlük PTF ler 24 saat önceden toplu olarak belirlenmektedir.
- Tahmin yapılırken en erken p-24 fiyat verisi kullanılabilir.



NOKTA TAHMİNLERİNİ DEĞERLENDİRMEK

- Elektrik fiyat tahminlerini içeren makalelerin büyük bir çoğunluğu nokta tahmini ele almaktadır.
- En çok kullanılan tutarlılık ölçümü teknikleri mutlak hataları (AE) temel almaktadır: $AE_h = |P_h - \hat{P}_h|$ burada P_h gerçekleşen fiyat ve \hat{P}_h ise tahmin edilen fiyattır.
- Bilhassa, saatlik nokta tahminleri için, günlük/haftalık ortalama mutlak hata (MAE), $T = 24$ veya 168 mutlak hata teriminin ortalaması olarak hesaplanmaktadır.



NOKTA TAHMİNLERİNİ DEĞERLENDİRMEK

- Farklı çalışmalar arasında, AE değerlerini hesaplamak zor olduğundan dolayı, birçok yazar mutlak yüzdellik hataları (APE) kullanmaktadır:

$$APE_h = AE_h/P_h$$

- Açık ara ile en popüler olan hata ölçüsü, T adet mutlak yüzdellik hatanın ortalaması olarak hesaplanan, ortalama mutlak yüzdellik hatadır (MAPE).
- Yük tahmini yapılırken, yük miktarı sıfırdan farklı olduğundan dolayı, MAPE oldukça kullanışlı olmasına rağmen, elektrik fiyatlarına uygulandığından MAPE hatalı yönlendirme yapabilmektedir.
- Özellikle, elektrik fiyatlarının sıfıra yakın olduğu durumlarda, gerçek mutlak hatalara rağmen, MAPE değerleri oldukça büyük çıkmaktadır.



NOKTA TAHMİNLERİNİ DEĞERLENDİRMEK

- l^1 -tipi normlardan farklı olarak, kare ya da l^2 -tipi normlar da, genellikle daha çok ekonometrik makalelerde olmak üzere, kullanılmaktadırlar.
- Belki de en yaygın olarak kullanılanı (günlük ve haftalık) hataların ortalama karekoku (RMSE) olmaktadır.
- Bu ölçü, tahmin edilen ve gerçek fiyatların arasındaki farkın karesinin ortalamasının karekökü olarak hesaplanmaktadır.

$$RMSE_{T=24 \text{ veya } T=168} = \sqrt{\frac{1}{T} \sum_{h=1}^T (P_h - \hat{P}_h)^2}$$



NOKTA TAHMİNLERİNİ DEĞERLENDİRMEK

- Son olarak, herhangi bir endüstri standardının olmadığı ve hata kriterlerinin fazlasıyla değişkenlik gösterdikleri vurgulanmalıdır.
- Weron (2006)'da gözlemlediği gibi, isimler devamlı olarak kullanılmadığından, bu durum karmaşaya yol açabilmektedir.
- Örneğin, Contreras, Espínola, Nogales, ve Conejo (2003); Garcia, Contreras, van Akkeren, ve Garcia (2005) ve Nogales ve diğ. (2002), ortalama haftalık hatayı, **haftalık MAPE** olarak tanımlarken, Conejo, Contreras, Espinola, ve Plazas (2005) ve Conejo, Plazas, Espínola, ve Molina (2005) DMAE denklemini $T = 168$ olarak kullanmışlardır.
- Benzer bir şekilde, sonraki üç çalışmada, haftalık RMSE, \sqrt{FMSE} olarak tanımlanmış ve RMSE formülünde $T = 168$ olarak kabul edilerek hesaplanmıştır.
- Farklı makalelerin karşılaştırılmalarına, Aggarwal ve ark. (2009b) olduğu gibi, dikkatle ile yaklaşılmalıdır.



R KODLARI

```
Library(forecast)
fit.ann <- nnetar(p0)
fit.ann
for.ann<-forecast(fit.ann, h=7)
accuracy(for.ann, p0.test)
res3<- p0.test- for.ann$mean
fit.annx <- nnetar(p0, xreg=xreg.training)
fit.annx
for.annx<-forecast(fit.annx, xreg=xreg.test)
accuracy(for.annx, p0.test)
res4<- p0.test- for.annx$mean
```

EĞİTME VE TEST MODELLERİNİN MAPE DEĞERLERİ İLE KARŞILAŞTIRILMASI



	MAPE					
Model	T1_Eğitme	T1_Test	T2_Eğitme	T2_test	T3_Eğitme	T3_Test
(S)AR(I)MA	2.16	5.17	1.62	4.34	3.29	7.28
(S)AR(I)MAX	1.39	4.01	1.46	3.86	2.94	6.64
ANN	0.66	4.19	0.98	4.82	1.97	8.36
ANNX	0.29	3.57	0.45	3.67	0.97	7.96



TESEKKURLER! SORULAR ?

*Ezgi AVCI, MSc, PhDc.
n.ezgi.avci@gmail.com*