



Çok Boyutlu Zaman Serilerinde Boyut Küçültme



Dr. Öğr. Üyesi Barış Akgün

Koç University

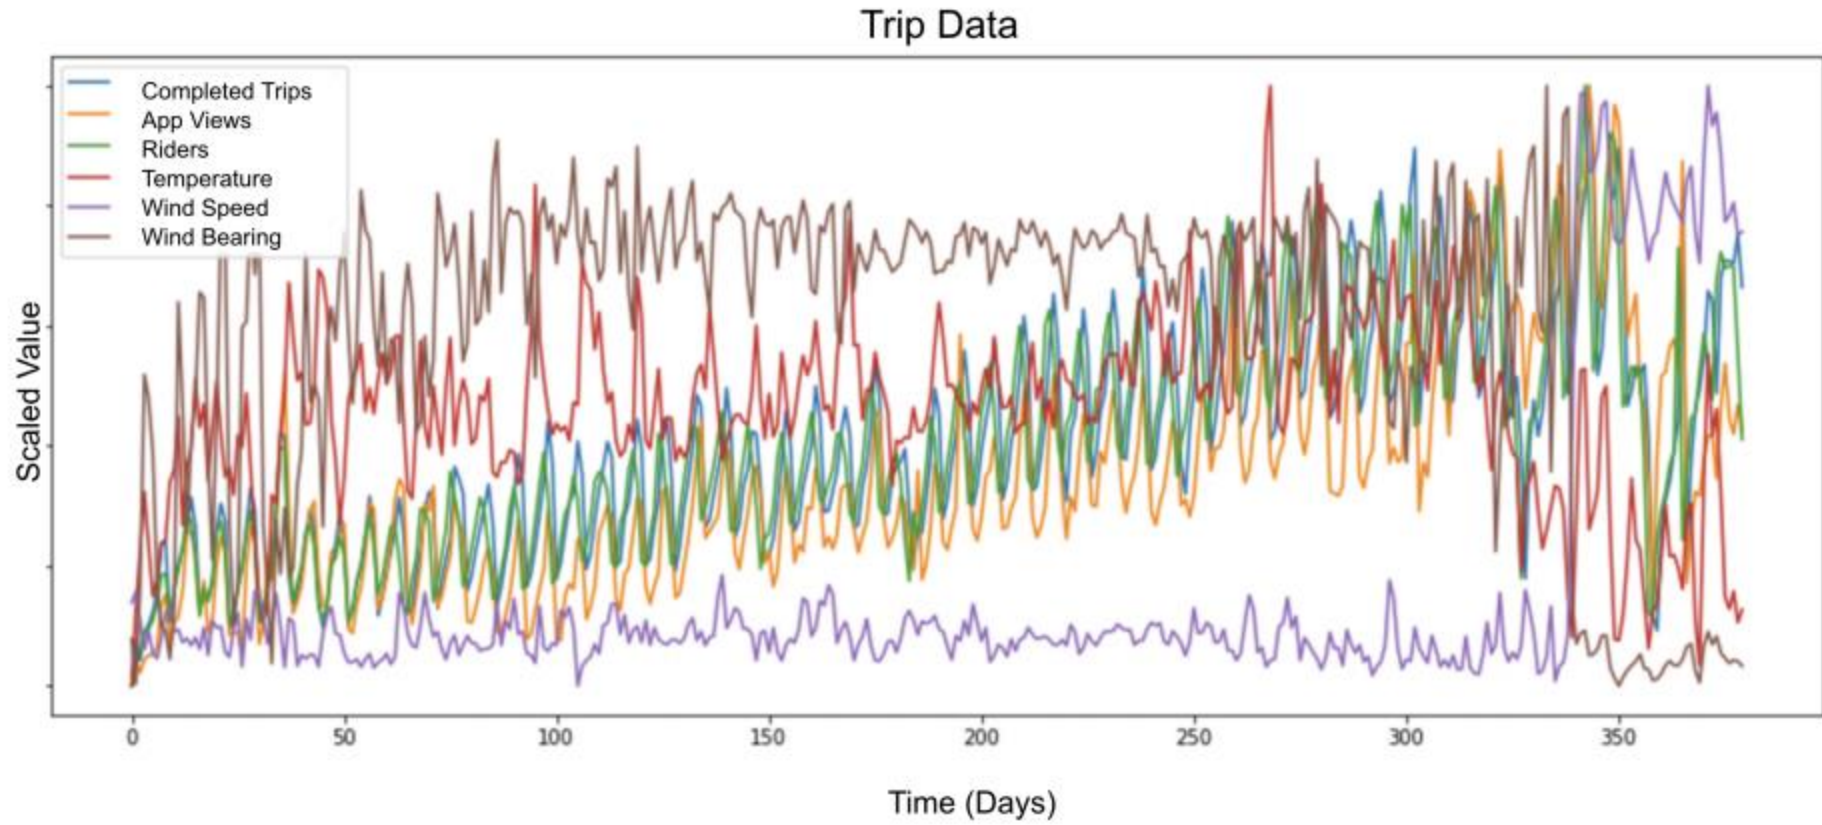
Küresel Isınma



Piyasalar



Uber Araç Kullanımı



Zaman Serileri Her Yerde


- Dijitalleşmiş fabrikalar
- Kentler
- Akıllı telefonlar
- Uydular
- Bilimsel veri toplama araştırmaları
- Ses, Video
- Robot/Drone/Otonom Araç Sensörleri
- Metin ve Gen Verileri (Tam olarak zaman serisi değil ama sıralı yinede sıralı)
- ...

Zaman Serileriyle Ne Yapmak İsteriz?


- Gelecek deęerlerini tahmin etmek (forecasting)
 - Örn: Yarın borsa ne olacak?
- Gözlemlenen bir serinin sınıflandırılması
 - Örn: Akıllı saat verilerinden aktivite tanıma
- Aykırılık (anomaly) Tanımlama
 - Örn: Rafineri süreci sıcaklık ölçümleri
- Kümeleme
 - Örn: Farklı kuş şarkılarını gruplama
- Arama/Endeksleme
 - Örn: Dinlediğim şarkının adını ya da dinlediğim şarkıya en benzer şarkıyı bulma
- Deęişim zamanı bulma
 - Makroekonomik trendlerin deęişme zamanları

Sadece bunlarla sınırlı deęil!

Temel Zaman Serisi Tipleri




Durađan

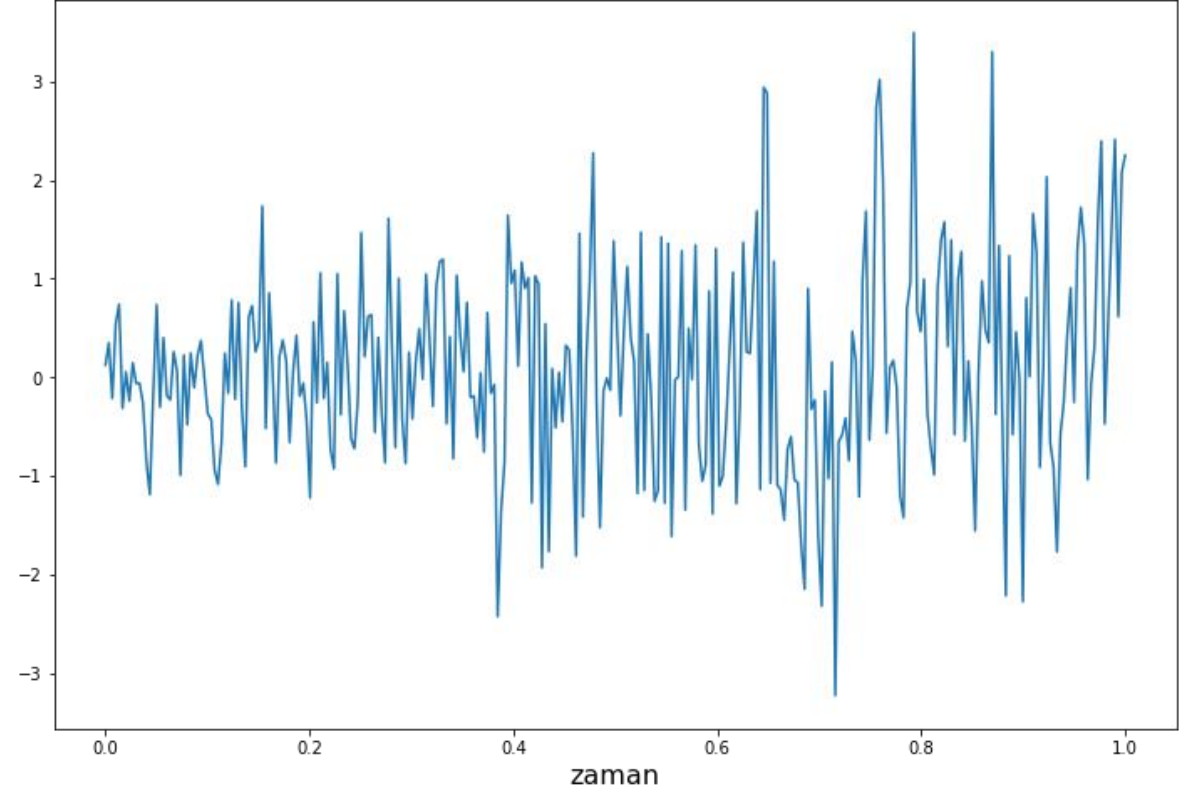


Trend

Temel Zaman Serisi Tipleri



Sezonsal



Artan Varyans

- Bir zaman serisi gördüklerimizin karışımından da oluşabilir
- Daha karmaşık da olabilir

Gecikme

- Elimizdeki zaman serisi:

$$X = x_1, x_2, \dots, x_{t-1}, x_t, x_{t+1}, \dots$$

- x_t 'ye göre i 'inci gecikme

$$G(x_t, i) = x_{t-i}$$

- Birinci derece sezonsal olmayan fark:

$$\Delta x_t = x_t - x_{t-1}$$

- İkinci derece sezonsal olmayan fark (farkların farkı)

$$\Delta^2 x_t = \Delta x_t - \Delta x_{t-1} = x_t - 2x_{t-1} + x_{t-2}$$

- Sezonsal fark (sezon periyodu s)

$$\Delta_s x_t = x_t - x_{t-s}$$

Otokorelasyon

μ : Ortalama
 σ : Standard sapma

- Kovaryans:

$$\text{cov}(X, Y) = \frac{1}{N} \sum_{i=1}^N (X_i - \mu_X)(Y_i - \mu_Y)$$

- Korelasyon:

$$\text{corr}(X, Y) = \frac{\text{cov}(X, Y)}{\sigma_X \sigma_Y}$$

Otokorelasyon

μ : Ortalama
 σ : Standard sapma

- Otokorelasyon



$$\text{autocorr}(X, i) = \frac{\text{cov}(X, G(X, i))}{\sigma_X \sigma_{G(X, i)}}$$

- Durağanlık varsayımı altında $\sigma_X = \sigma_{G(X, i)}$:

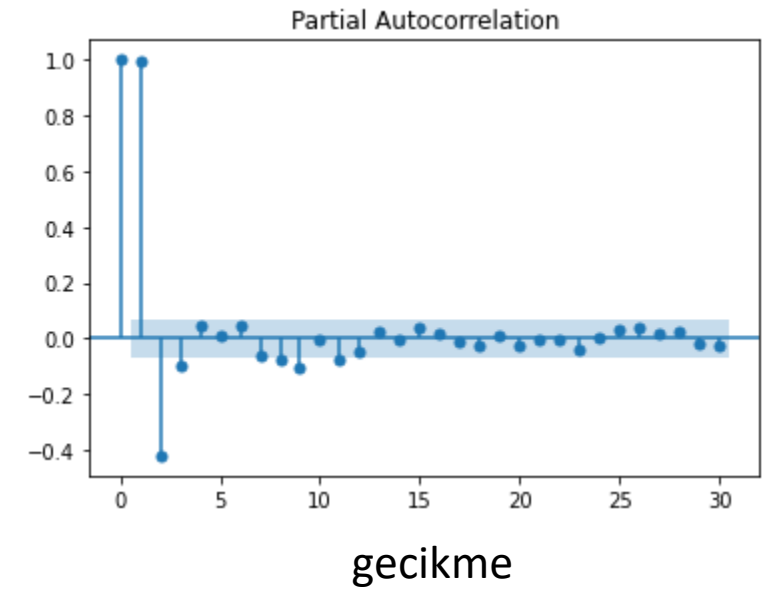
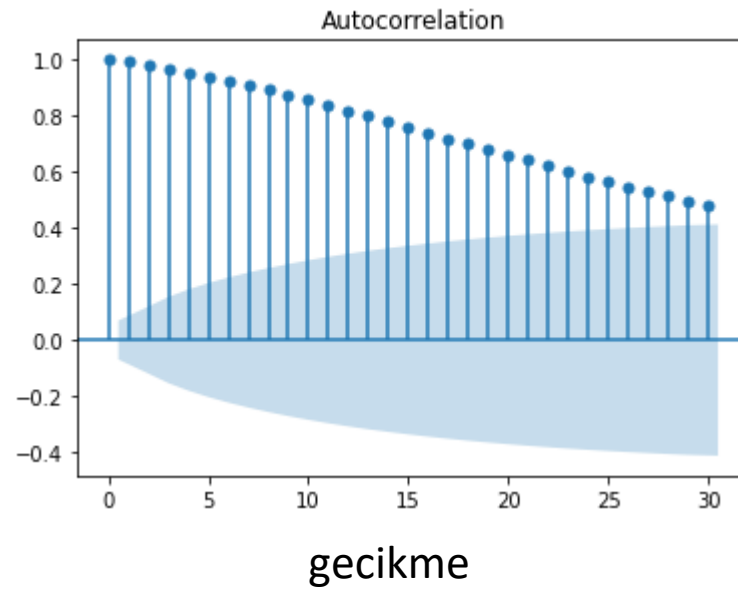

$$\text{autocorr}(X, i) = \frac{\text{cov}(X, G(X, i))}{\sigma_X^2}$$

- Kısmi Otokorelasyon: Daha kısa gecikme etkilerinden arındırılmış otokorelasyon

Wikipedia'dan Örnek:



Örnek



Bazı Modeller

Ak gürültü modeli: $\mathcal{N}(0, \Sigma_\epsilon)$

- Regresyon modelleri

$$y_t = w^T X_t + \epsilon_t$$

- y : scalar çıktı, X : d boyutlu değişken, w : parametre vektörü, ϵ : scalar ak gürültü

- Otoregresyon modelleri

$$X_t = AX_{t-1} + E_t$$

- A : $d \times d$ kare parametre matrisi, E : ak gürültü vektörü

Bazı Modeller

- Hareketli Ortalama Modelleri

$$X_t = AX_t + \Theta E_{t-1} + E_t$$

- Θ : $d \times d$ hareketli ortalama parametre matrisi, E_{t-1} : tamin edilen X_{t-1} ile gerçek X_{t-1} arasındaki fark (ak gürültü olarak varsayılır)

- Kırılma noktalı modeller

$$X_t = A_1 X_{t-1} I(t \leq \tau) + A_2 X_{t-1} I(t > \tau)$$

- τ : kırılma noktası, I : indikatör fonksiyonu (içi doğru ise 1, değilse 0)

Bazı Modeller

- Kontrol modelleri

$$X_T = AX_{t-1} + BU_t + E_t$$

- $B: d \times d$ kare matris, $U: d$ –boyutlu control değişkeni

- Faktör modelleri

$$X_t = \Lambda F_t + E_t$$

- $F: k$ boyutlu faktörler/gizli değişkenler ($k < d$), $\Lambda: d \times k$ parametre matrisi
- Faktörler de dinamik olabilir:

$$F_t = \Phi F_{t-1} + U_t$$

ARIMA Modelleri

- ARIMA(p,d,q):
 - p: Otoregresyon terim sayısı
 - d: Sezonsal olmayan fark derecesi
 - q: hareketli ortalama terim sayısı
 - (Ufak Not: p ve d çok alakalı)

- Genel model (p>d için):

$$x_t = \mu + \phi_1 x_{t-1} + \dots + \phi_p x_{t-p} + \theta_1 e_{t-1} + \dots + \theta_q e_{t-q} + \epsilon_t$$

- x_t skalar

Klasik Yaklaşım

1. Seriyi durağan bir hale getir
 - Ardışık değerlerin farkını al (trend için)
 - Sezonasal değerlerin farkını al (sezonsallık için)
 - Logaritmasını al ya da indir (deflate)
2. Otokorelasyon ve kısmi otokorelasyon değerlerine bakıp, ARIMA parametrelerini seç
 - Bu konuda yardımcı olacak kaynaklar mevcut
3. Tahmin ile gerçek değerlerin farkına bak:
 - Ak gürültü gibi davranıyorsa işimiz bitti
 - Değilse farkın otokorelasyon ve kısmi otokorelasyon değerlerini incele ve 2. adıma dön

Çok Boyutlu: Vektör Otoregresyon Modeli (VAR)

- d boyutlu bir zaman serisi için:

$$X_t = \mu_X + A_1 X_{t-1} + A_2 X_{t-2} + \dots + A_p X_{t-p} + \epsilon_t$$

- $\epsilon_t \sim \mathcal{N}(0, \Sigma_\epsilon)$ (özdeş ve bağımsız olarak dağılmış, i.i.d)
- A_i : $d \times d$ matrisler
- Örnek:
 - Varsayımlar:
 - BIST100 hisseleri birbirlerini etkiliyor (100 hisse)
 - 1 dakika arayla veri topluyoruz
 - Son 10 dakikaya bakacağız
 - Kaç tane parametre var?
 - $100 + 100 \times 100 \times 10 \approx 10^5$!!!

VAR

- A_i : matrislerinin seyrek (sparse) olduğu varsayımı altında Lasso yöntemi (parametrelerin l_1 düzenlileştirilmesi) ve onun varyantları ile çözülür
- Ancak yüksek boyutlu verilerde, Lasso yönteminin iyi çalışacağı kesin değildir
- Ne yapılabilir?
 - Problem hakkında öncül bilgiler kullanmak (örneğin tarım hisseleri ile teknoloji hisselerini bağımsız kabul etmek, tarım teknolojisi şirketleri hariç)
 - Daha az parametrelili modeller denemek
 - Zaman serisinin boyutlarını küçültmek
 - Başka?

Az Parametrelili Modele Basit Örnekler

- Parametre matrislerini scalar değerlerle değiştirmek

$$X_t = \mu_X + \alpha_1 X_{t-1} + \alpha_2 X_{t-2} + \dots + \alpha_p X_{t-p} + \epsilon_t$$

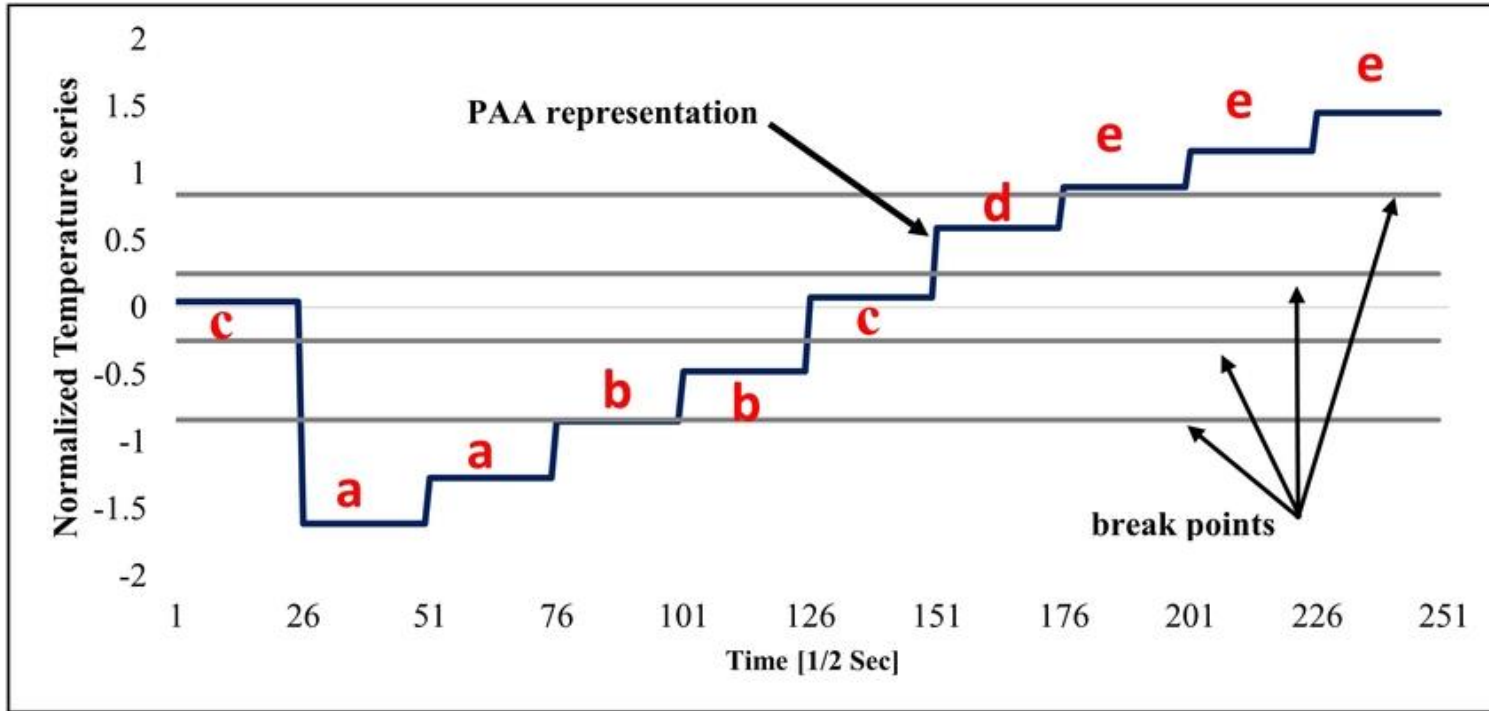
- Hisse Örneği: 110 parametre
- Parametre matrislerini köşegen olarak varsayma
 - Hisse Örneği: 1100 parametre
- Faktör Modelleri kullanma?

Zaman Serilerinde Boyut Küçültmek

- Zamanda boyut küçültmek
 - Bazen zamandan bağımsız bir gösterim bulmak
- Ölçüm uzayında boyut küçültmek
- Hem zamanda hem ölçüm uzayında boyut küçültmek
- Sürekli ölçümlerden sembol çıkartmak
 - Hem zaman hem de ölçüm uzayında

Örnek: PAA ve SAX

- “Piecewise Aggregate Approximation” ve “Symbolic Aggregate Approximation”




Kabaca:

- Ayrık zaman pencelerindeki değerleri ortalamaları ile değiştir
- Bu değerlere sembol ata
- Çok boyut versiyonları mevcut ama ...

Şekil Aremu vd.


Örnek: Saklı Markov Modelleri

- Özellikle Hiyerarşik SMMler Öğrenerek hem zamanda boyut küçültme hem de sembol çıkartma yapılabilir



Örnek: Dönüşümler

- Fourier, Dalgacık vb.
- Zaman serisinin dönüşümlerini hesapla
- Katsayılar zaman serisini anlatıyor
- Örnek: Video sıkıştırması!
- Boyut sayısı arttıkça pratikliğini kaybedebiliyor



Wikipedia: JPEG dönüşüm örneği

(Dinamik) Faktör Modelleri


- Hatırlayalım

$$\begin{aligned}X_t &= \Lambda F_t + E_t \\F_t &= \Phi F_{t-1} + U_t\end{aligned}$$

- F_t boyutu X_t boyutundan daha küçük
- Daha fazla F gecikmesi de eklenebilir
- Hem Λ hem de F bilinmiyor
 - Λ : Birimdik (ortonormal) varsayılırsa kapsadığı doğrusal uzay özgün
 - Bu sayede kestirim mümkün
- F boyutunun veriden belirlenmesi de mümkün
 - Hatalar ak gürültü olana kadar ara
 - Ya da bir bilgi kriterine göre seç

Doğrudan Boyut Küçültmek

- Gözlemleri özdeş ve bağımsız olarak dağılmış olarak kabul et
 - Not: Zaman serisi analizine ters!
- Bildiğimiz yöntemler ile boyut küçült. Örn:
 - Temel Bileşen Analizi (TBA)
 - UMAP
- Zaman serisi modellemesini küçük boyutta yap
- Dezavantajları:
 - Yüksek boyuttaki zaman bilgisini kaybetme riski
 - Yüksek boyutta kovaryansı kestirimi sorunlu



Fonksiyonel Temel Bileşen Analizi

- Zaman serisi verisinden doğrusal yöntemler *özfonksiyonlar* (eigenfunctions) çıkarmak
- $X(t)$ rassal bir süreç olsun, $\mu(t) = \mathbb{E}[X(t)]$. Otokovaryansı:

$$\text{cov}(X(s), X(t)) = \sum_{k=1}^{\infty} \lambda_k \phi_k(s) \phi_k(t)$$

- $\lambda_k > 0$, özdeğerler, ϕ_k : özfonksiyonlar
- Bu süreci temel fonksiyonlar ile gösterebiliriz:

$$X(t) - \mu(X(t)) = \sum_{k=1}^{\infty} \xi_k \phi_k(t)$$

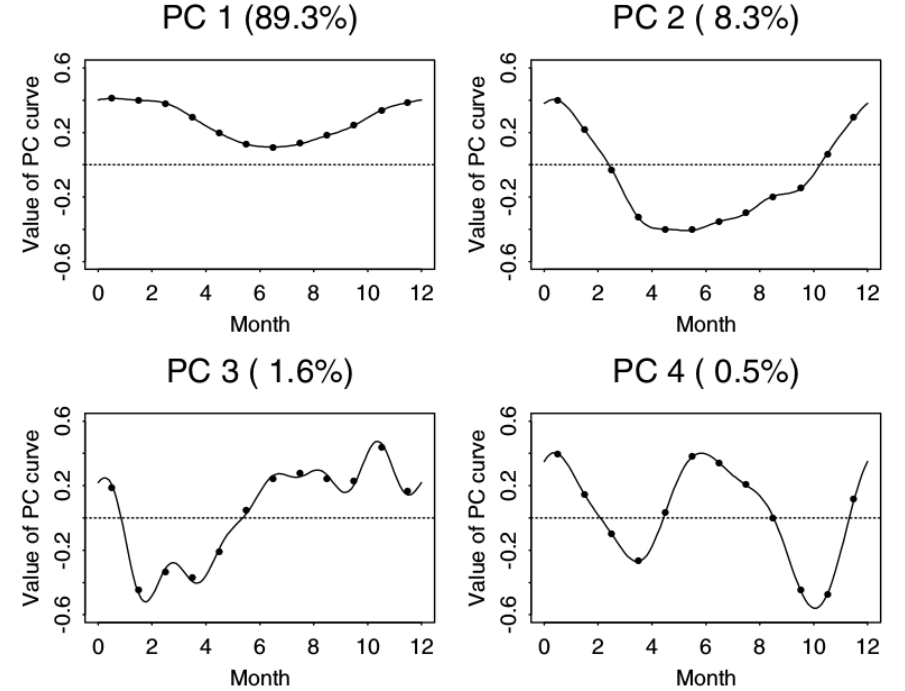
- ξ_k : temel bileşenler

Fonksiyonel Temel Bileşen Analizi

- Kullanım: m temel bileşen seçtikten sonra:

$$X(t) \approx \mu(X(t)) + \sum_{k=1}^m \xi_k \phi_k(t)$$

- Seyrek olmayan serilerde, zamanda düzenlileştirilmiş TBA ile eşdeğer
- Dönüşüm yaklaşımı olarak yorumlanabilir
- Faktör modeli öğrenmek için kullanılabilir



Ramsay ve Silverman

Bir Adım Geri


- Daha birçok model var:
 - ARCH, GARCH, TAR, LVARMA ...
- Parametresiz modeller de mevcut
 - Gauss Süreçleri
- Herhangi bir gözetimli öğrenme yöntemini, girdi ve çıktılarını ayarlayarak zaman serisi modeline çevirmek de mümkün

$$X_t = f(X_{t-1}, X_{t-2}, \dots, X_{t-p}, w)$$

- Yüksek boyutta gözlemler yapsak bile alttaki olaylar genelde daha düşük boyutlu varsayımı genelde doğru
- Boyut küçültme – gösterim öğrenme – derin modeller
 - Derin modeller doğru mimariler ile çok boyutlu verileri halledebiliyor

Yapay Sinir Ağı Zaman Serisi Mimarileri

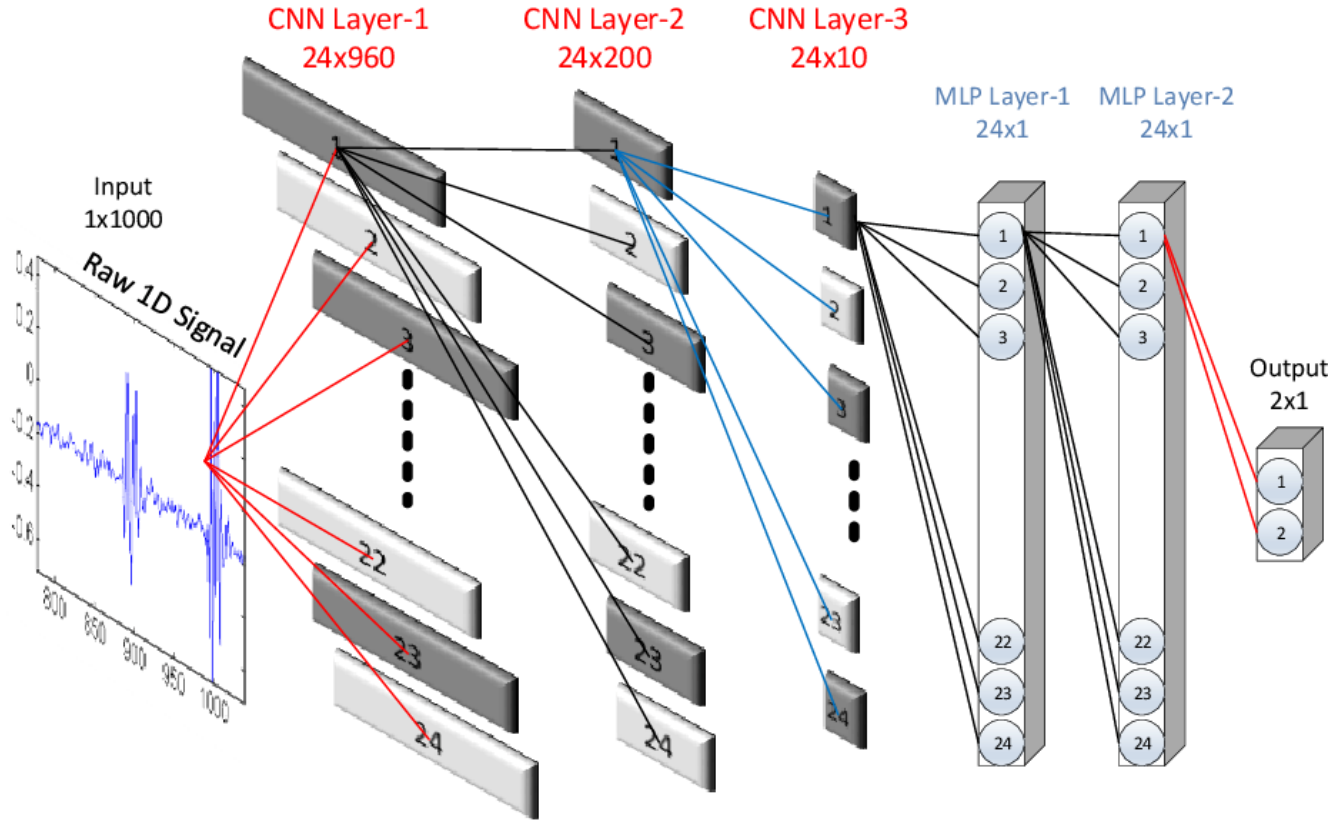
- Zaman Gecikmeli Sinir Ağı:



- Tek filtrelili 1 Boyutlu Evrimsel Sinir Ağı
- Çıktı zaman bağı bařka bir deęiřken olabilir

Yapay Sinir Ağı Zaman Serisi Mimarileri

- 1 Boyutlu Evrişimsel (Convolutional) Sinir Ağı – Zaman Ekseninde

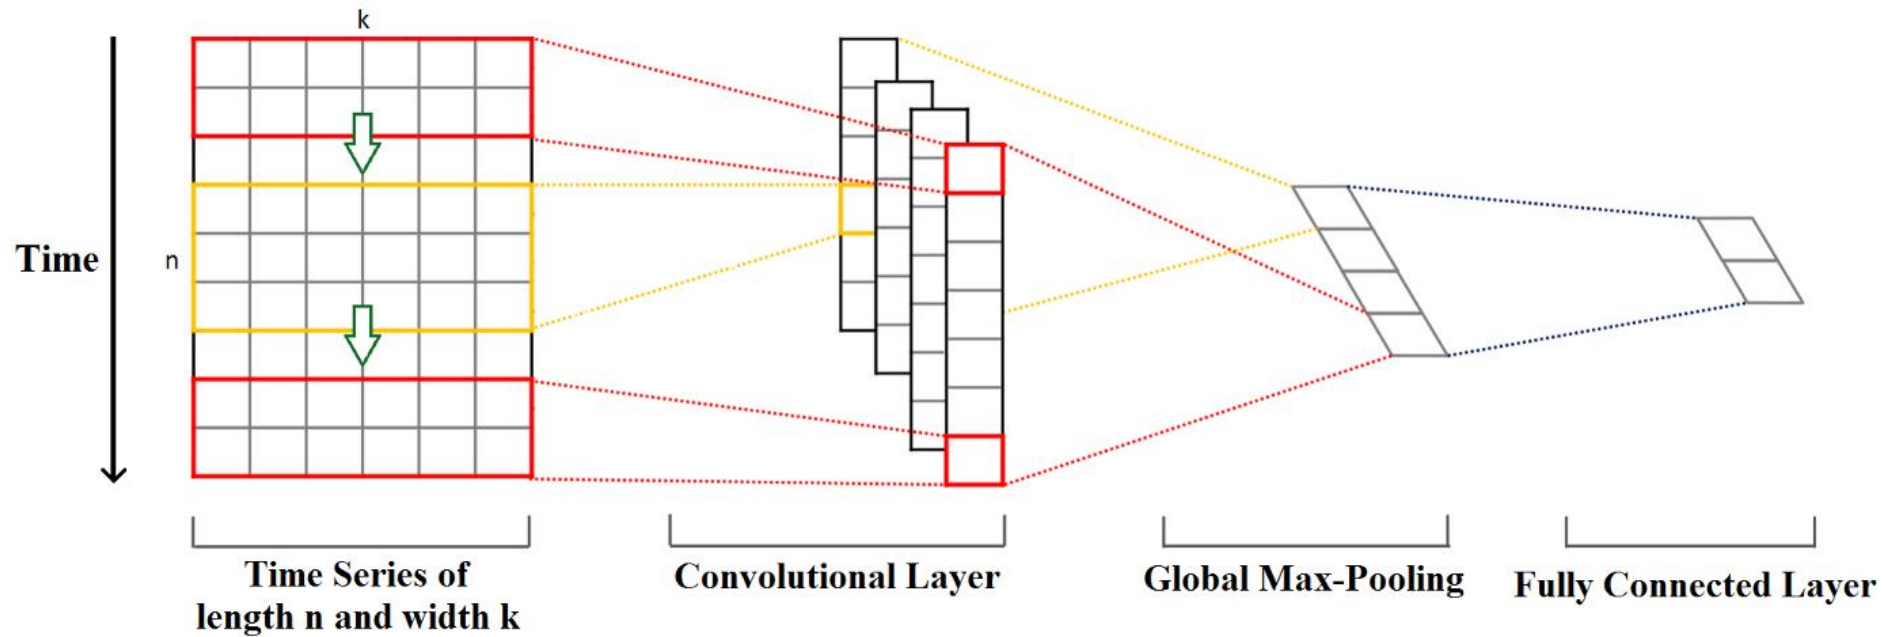


Kiranyaz vd.

- Evrişimsel ağlar, verilen ekseninde parametre paylaşırlar
- Bu sayede karmaşıklıkları azalır
- Aktivasyon fonksiyonları ve derinlik sayesinde de doğrusal olmayan bağlantıları öğrenirler
- Not: Evrişimsel ağlar, zaman serisi regresyonu için genelde çok iyi performans göstermezler

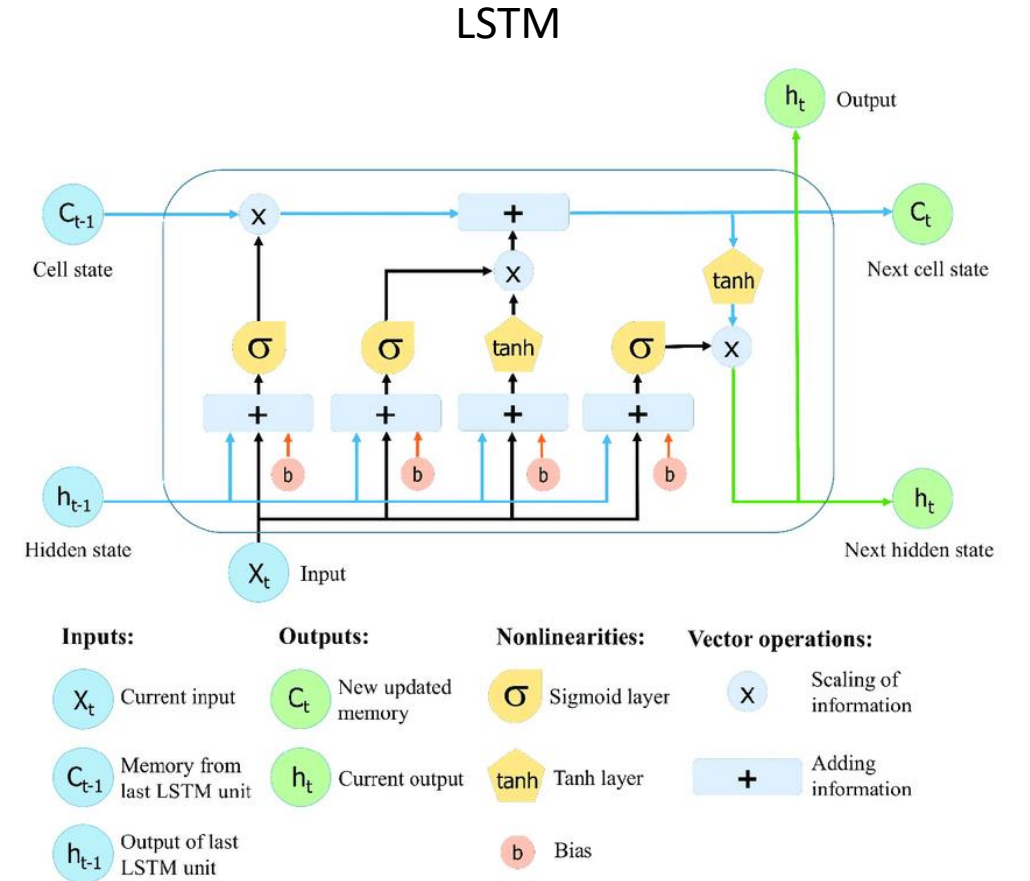
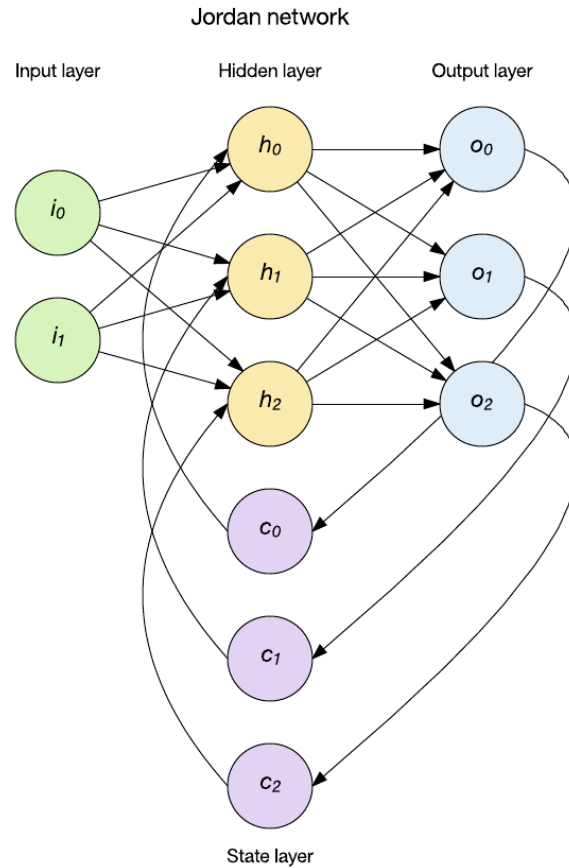

Yapay Sinir Ağı Zaman Serisi Mimarileri

- 1 Boyutlu Evrişimsel Sinir Ağı – Ölçüm Ekseninde



Yapay Sinir Ağı Zaman Serisi Mimarileri

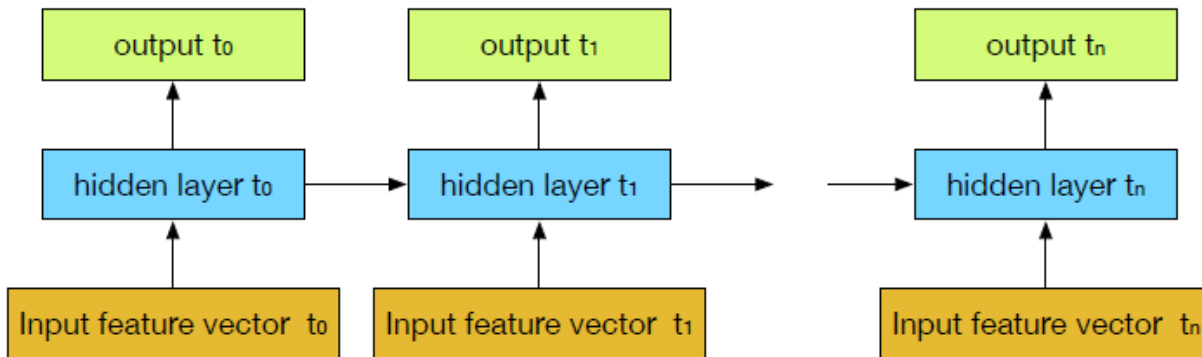

- Özyineli (Recurrent) Ağlar



Bir nevi “hafıza” özelliği katıyor

Yapay Sinir Ağı Zaman Serisi Mimarileri

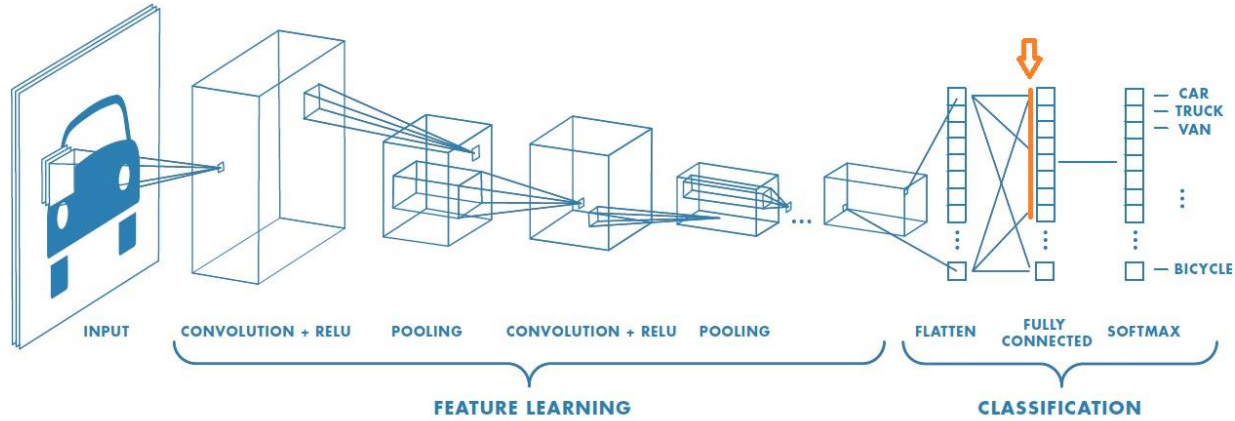
- Özyineli Ağlar



- Özyineli ağlar, zamanda parametre paylaşırlar
- Bu sayede karmaşıklıkları azalır
- Aktivasyon fonksiyonları ve derinlik sayesinde de doğrusal olmayan bağlantıları öğrenirler
- Zaman serisi regresyonunda genelde fena değildir.
- Çok boyutlu problemlerde, en genel VAR modellerinden çok daha hızlı sonuç verirler
- Hiyerarşik olarak kullanılabilir
- Özyineli katmanlardan önce evrimsel katmanlar eklenebilir


Yapay Sinir Ağları ile Basit Boyut Küçültme

Öğren ve
Tepesini Çıkart



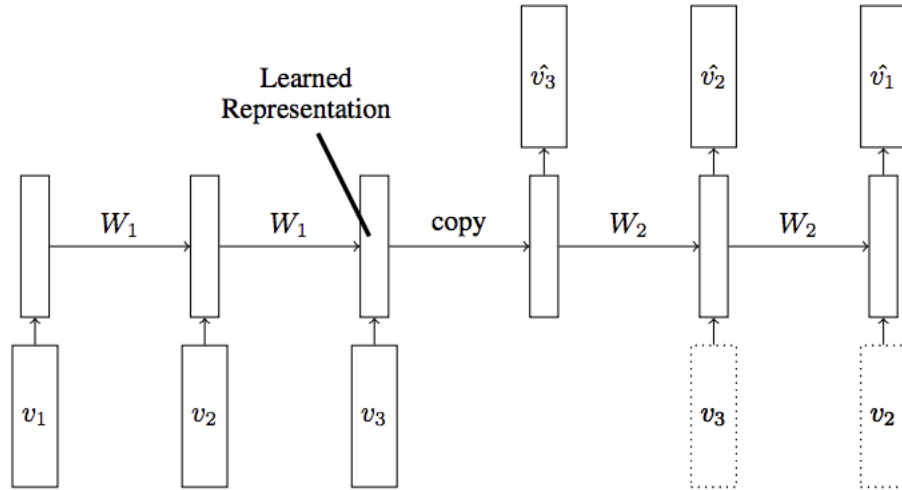
Aslında benzer!

Otokodlayıcı
(Gözetimsiz*)



YS ile Zaman Serilerinde Boyut Küçültme

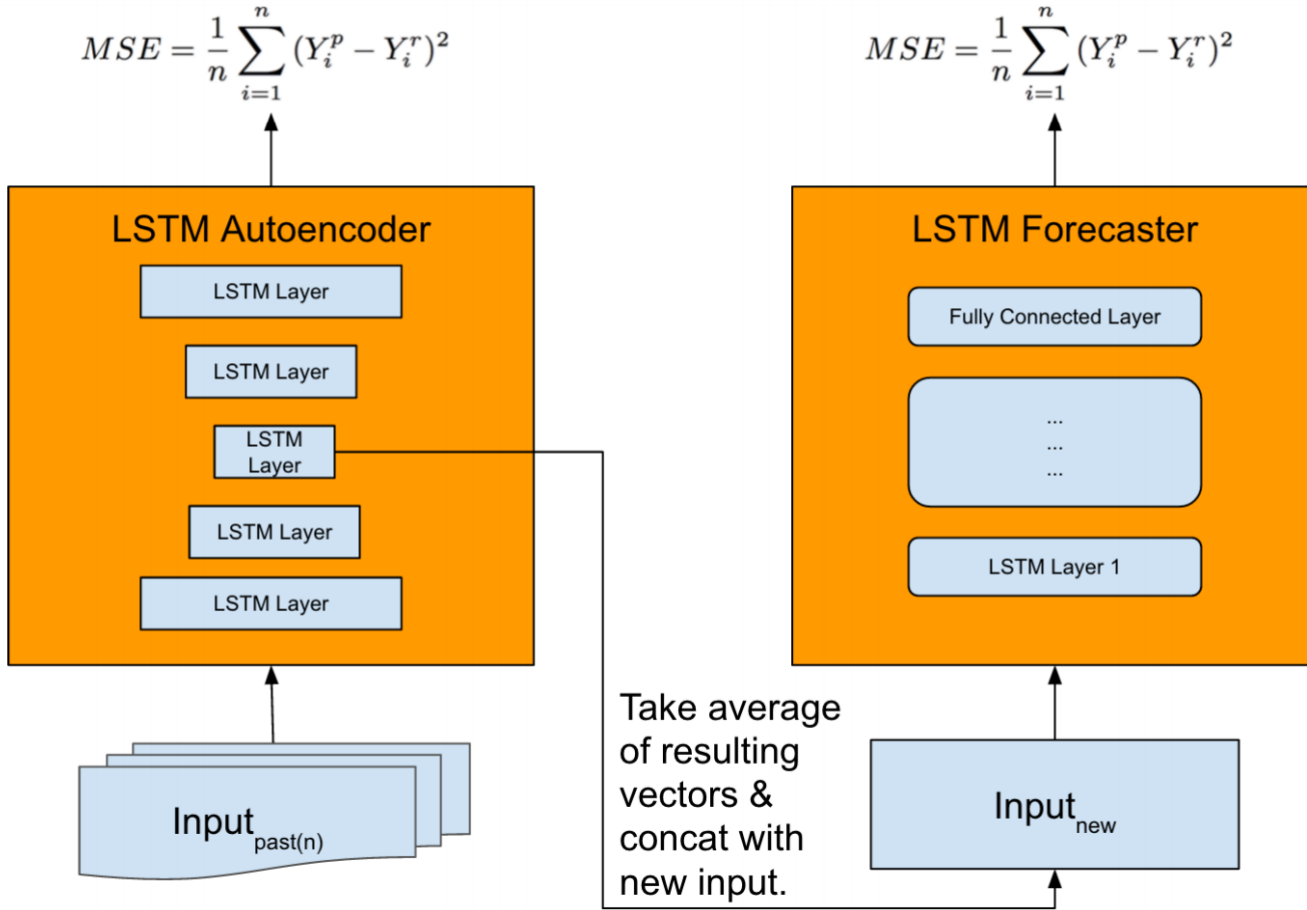
- Basit fikir:
 - Otokodlayıcı kulan
 - Kodlayıcı (ve istenirse çözücü) kısmını zaman serilerine uygun bir model olarak seç
 - Ara katmanı çıktısı düşük boyutlu gösterim olarak al



LSTM – LSTM otokodlayıcı

Srivastava vd.

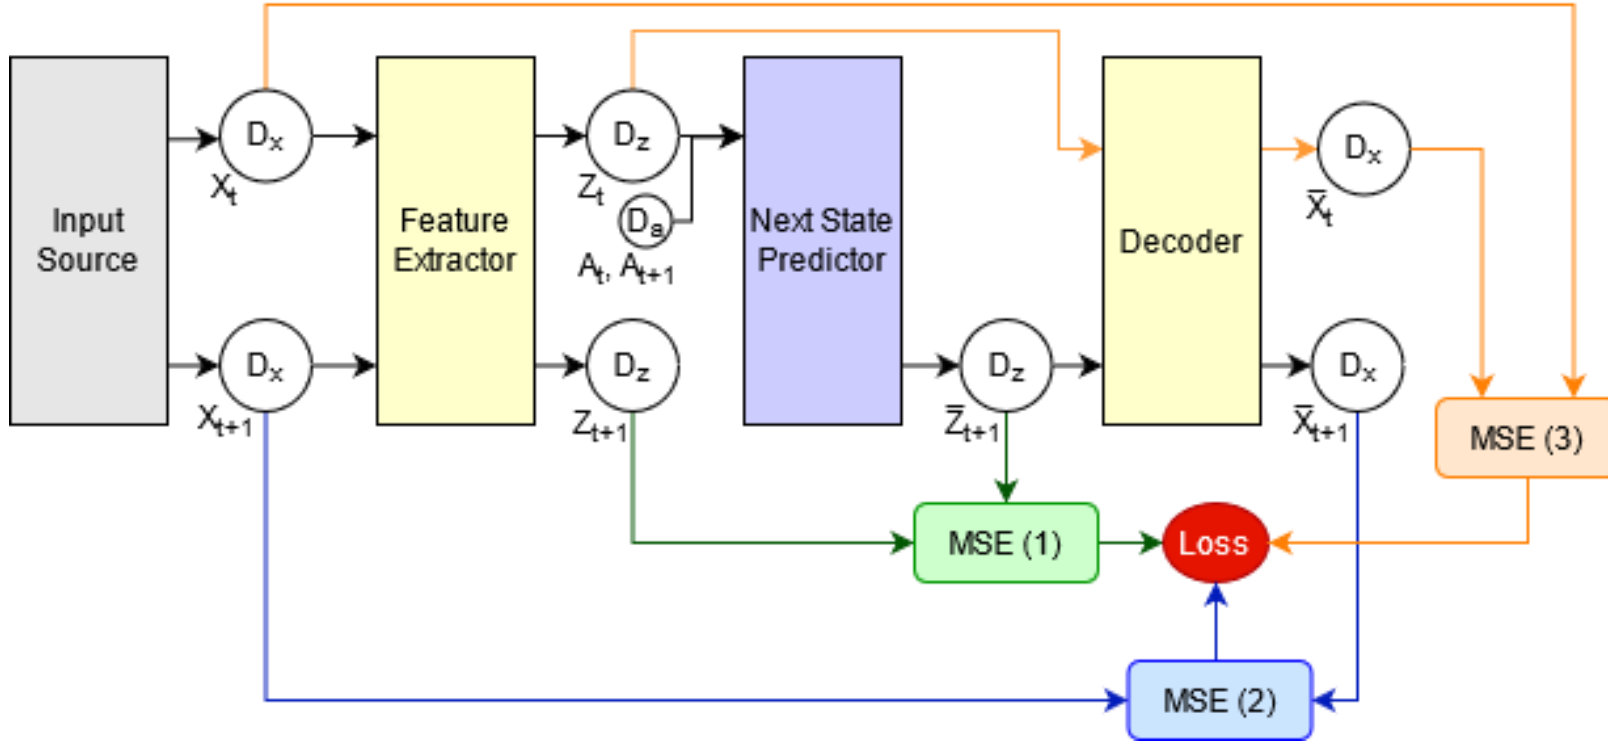
Uber Örneği



Laptev vd.

- Tahmin ve otokodlayıcı iç içe
- Uzun ve çok boyutlu zaman serilerinde ender olay tahmini için klasik yöntemlerden daha iyi çalışmış
- Kısa ve az boyutlu problemlerde klasik yöntemler daha iyi
- Uzun ve az boyutlu problemlerde performans benzer

Düşük Boyutta da Tahmin ve Karar Girdileri

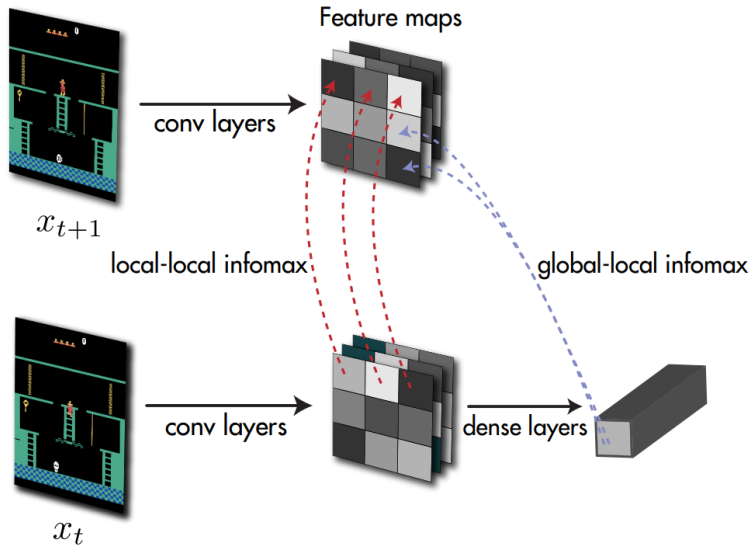


Serteli ve Akgün (deney aşaması devam ediyor)

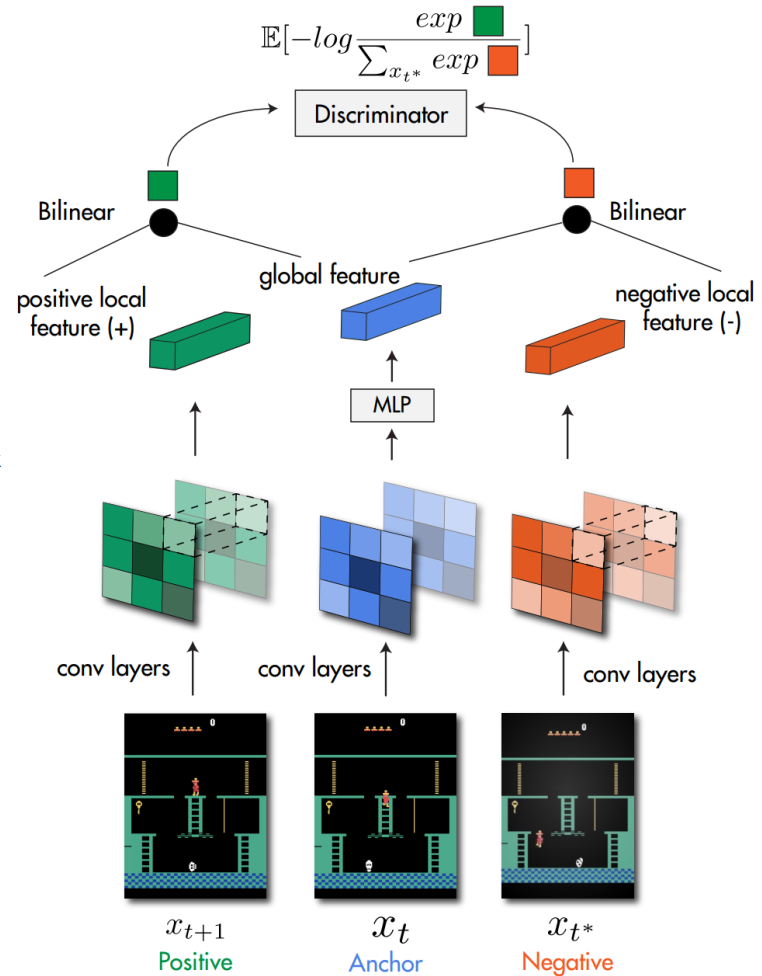
Not: Buna benzer mimariler mevcut. Detaylarda bizim uğraştığımız problemlere özelleşmiş kısımları var

- X : çok boyutlu veri
- Z : düşük boyutlu veri
- A : karar girdisi (örneğin robot aksiyonu)
- Aynı anda:
 - Çok boyut tahmini
 - Düşük boyut tahmini
 - Boyut küçültme
- Hafıza için mavi kutuda özinyeli katmanlar kullanılabilir
- “Az” veriden öğrenilebilecek şekilde tasarlandı

Ayrımsal (Contrastive) Yöntemler

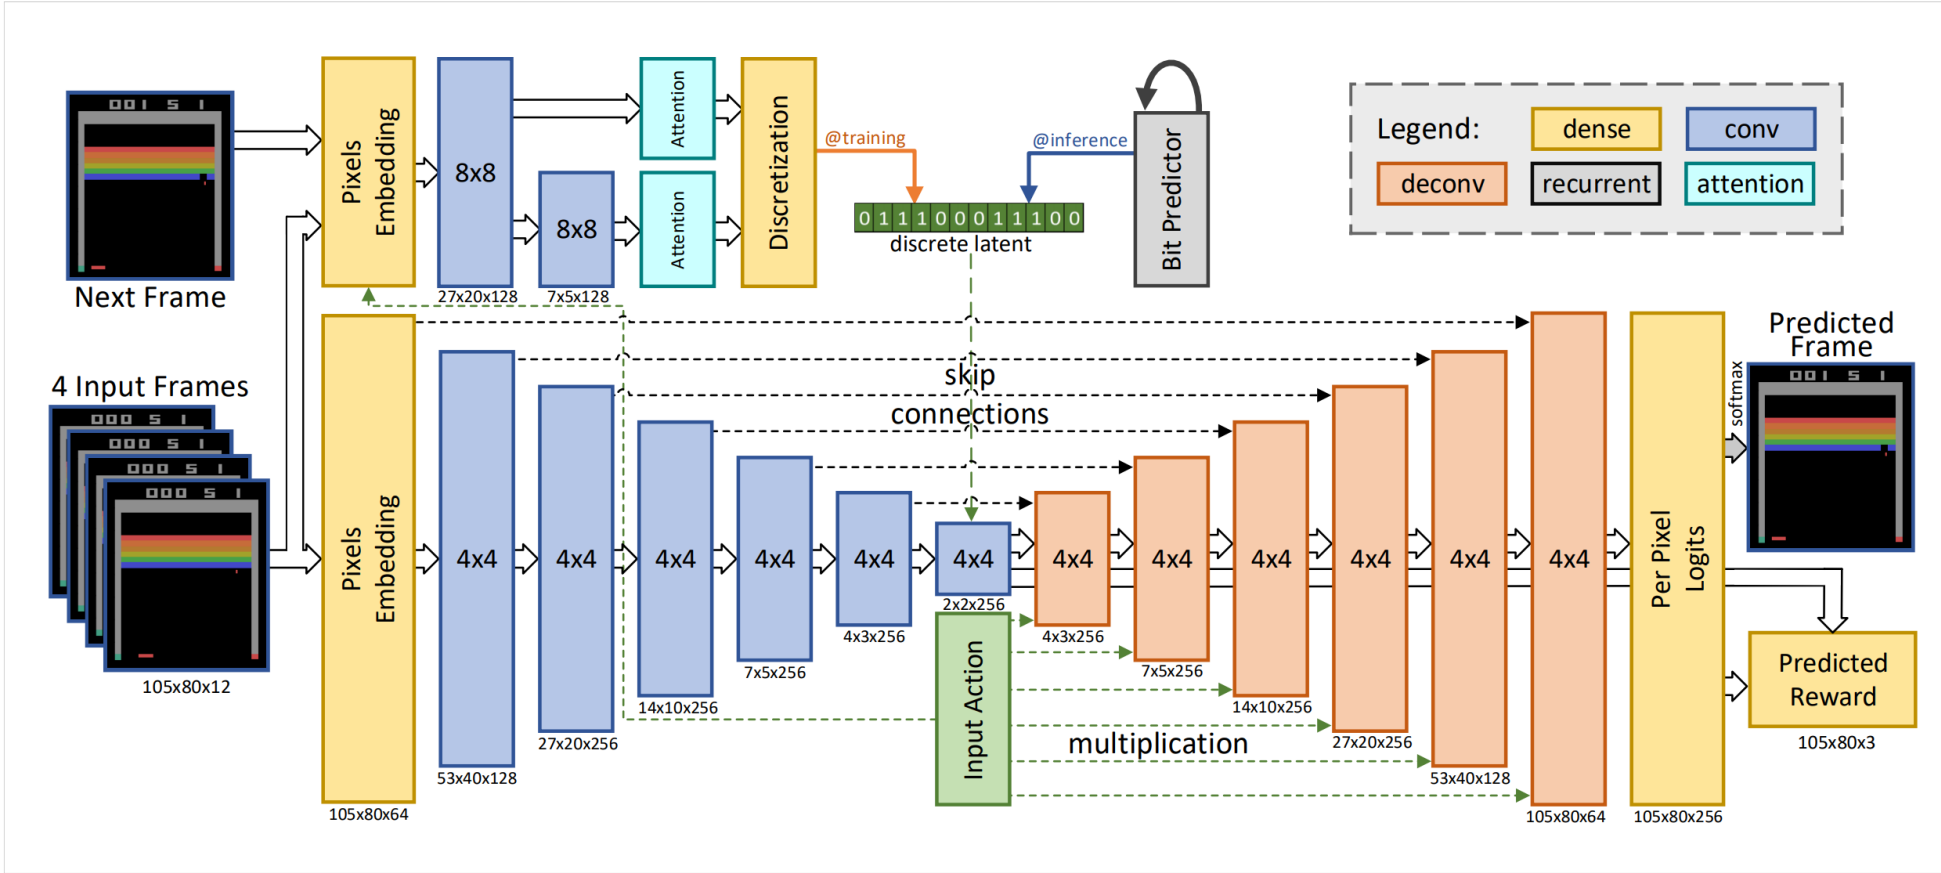


Anand vd.



- Mimari, iki durumu ayırması ve böylece daha iyi gösterim öğrenmesi için zorlanabilir
- Bu örnekte, bir sonraki Atari ekranı, şimdiki Atari ekranından tahmin edilmeye çalışılıyor
- Çok veri gerekli

Pekiştirmeli Öğrenme ile Beraber

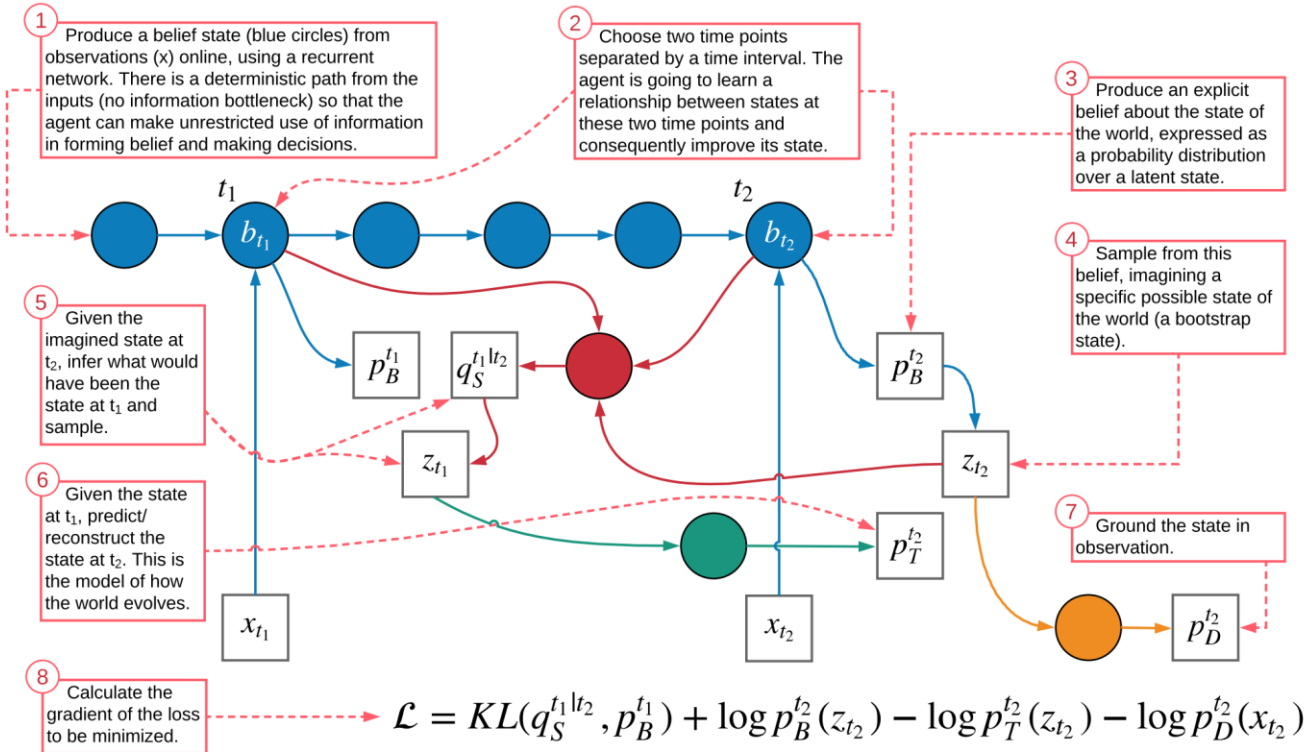


Kaiser vd.

- Küçük boyut aksiyon etkisi için kullanılıyor
- Arka plan çok değişmediği için mantıklı
- Ancak küçük boyut kullanılmıyor

Hem Düşük Boyut Hem Simülasyon

- Zamansal Fark Değişimsel Otokodlayıcı (Temporal Difference Variational Autoencoder - TD-VAE)



- Belief network (filtering)
- Inference network (smoothing)
- State prediction network (forward model)
- Decoder network (observation model)

- Düşük boyutlu soyut bir gösterim öğren
- Durum ile ilgili belirsizliği temsil et
- Gelecek tahminlerini olasılıksal yap (yani farklı tahminler mümkün)
- Eksik: Aksiyonlar yok

Neleri Konuşamadık:

- Farklı problem tipleri için yaklaşımlar ve farklı mimariler
 - Saf zaman serileri
 - Kontrol problemleri
 - Dil
 - ...
- Derin yaklaşımlarla sembol öğrenme
- Boyut küçültme öncesi ve sonrası uygulama karşılaştırmaları
- Sürekli öğrenmek ve durağan olmayan problemler

Sonuçlar

- Zaman serileri her yerde. Git gide miktar ve boyut olarak da artıyor
- Geleceği tahmin etmek zor, dünya sürekli değişiyor
- Farklı disiplinlerde benzer problemler mevcut
- Derin modeller aşağıdaki koşullarda tercih edilmeli:
 - Yorumlanabilirlikten taviz verebiliyorsak (bunu çok yapıyoruz, gidişat pek iyi değil)
 - Yeterince uzun veri varsa (ya da mimarimiz özelleşmiş ise)
 - Gözlemler çok boyutluysa
 - Aynı veri ile birden fazla problem ile uğraşacaksak
 - Durağan olmayan problemler (sürekli öğrenerek)