

**MARMARA ÜNİVERSİTESİ
TEKNİK BİLİMLER MESLEK
YÜKSEKOKULU**

WEB MİNING ARAŞTIRMA VE UYGULAMA

Bitirme Projesi

**Haydar ŞAHİN
360115023**

Bölüm : Bilgisayar Teknolojileri

Program: Bilgisayar Programcılığı

Danışman : Öğr.Gör.Dr. ZEHRA AYSUN ALTIKARDEŞ

2017

**MARMARA ÜNİVERSİTESİ
TEKNİK BİLİMLER MESLEK
YÜKSEKOKULU**

WEB MİNİNG ARAŞTIRMA VE UYGULAMA

Bitirme Projesi

**Haydar ŞAHİN
360115023**

**Bölüm : Bilgisayar Teknolojileri
Program: Bilgisayar Programcılığı**

Proje Sınavı :

Doç. Dr. Vedat TOPUZ

Öğr.Gör.Dr. Zehra Aysun ALTIKARDEŞ

Öğr.Gör. Fatih KAZDAL

Öğr.Gör. Ercan ERKALKAN

Öğr.Gör. Bekir Kurt

Özgünlük Bildirisi

1. Bu çalışmada, başka kaynaklardan yapılan tüm alıntılar, ilgili kaynaklar referans gösterilerek açıkça belirtildiğini,
2. Alıntılar dışındaki bölümlerin, özellikle projenin ana konusunu oluşturan teorik çalışmaların ve yazılım/donanımın benim tarafımdan yapıldığını bildiririm.

WEB MİNİNG ARAŞTIRMA VE UYGULAMA

(ÖZET)

Son yüzyılda gerçekleşen gerek sanayi, gerekse teknoloji alanındaki gelişmeler ile internet adını verdiğimiz evrensel ağıımız oluşmuş, hatta oluşmakla kalmayıp Birleşmiş Milletler İnsan Hakları Konseyi tarafından temel insan hakkı olarak ilan edilmiştir[1]. Günümüzde hayatımızın değişmez bir parçası haline gelen bu teknoloji, insanların verilerini paylaşmasını sağlamış ve ortaya veri yığınları çıkmıştır. Öyle ki IBM şirketi dünyadaki tüm verilerin %90'ının son iki yılda üretildiğini söylüyor[2]. Ortaya çıkan bu verinin son dönemlerde literatürde adını sıkça duyduğumuz nesnelere internet kavramı ile daha da artması beklenmektedir. Hal böyle olunca ortaya çıkan veri karmaşıklığından anlamlı bilgiler elde etmek amacı ile veri madenciliği (data mining) ve Web madenciliği (web mining) kavramları ortaya çıkmıştır.

Bu metnin tamamında web madenciliği ve buna bağlı olarak veri madenciliği konuları işlenmektedir ancak genel manada bir tanımlama yapacak olursak, Veri madenciliği bir çok kaynaktan toplanan karmaşık örtülü verinin insanın kolaylıkla algılayabileceği elzem veriye dönüştürülmesidir[3]. Çalışmada veri ve web madenciliği konuları teorik ve uygulamalı örnekler olarak iki aşamada incelenmiştir.

Bu çalışmada matematik, istatistik ve bilgisayar bilimlerinden yararlanarak, Knime adlı uygulama ile internet üzerinden TCMB kur verileri edinilip, bu verilerin diğer niteliklerle ön işleme ve bilgi çıkarımı yapılacaktır.

İÇİNDEKİLER

1. GİRİŞ	6
2. PROJENİN TANIMI VE PLANI	7
3. KURAMSAL BİLGİLER	8
3.1 Veri Nedir ?	8
3.2 Veri Madenciliği Nedir ?	8
3.3 Veri Madenciliği Metotları	10
3.3.1 İnkelleme (Regression)	12
3.3.2 En Yakın Komşu (K-Nearest Neighbors)	13
3.3.1 3.3.3 Karar Ağacı (Decision Tree)	14
3.3.4 Destek Vektör Makinesi (Support Vector Machine)	14
3.4 Projedeki Nitelikler (Attributes)	15
4. TASARIM, GERÇEKLEME	16
5. SONUÇ ve ÖNERİLER	30
KAYNAKLAR	31
ÖZGEÇMİŞ	33

I. GİRİŞ

Günümüzde devletler dahil pek çok kurum elindeki paranın değerini en iyi şekilde korumak hatta arttırmak istemektedir. Dalgalanan döviz kurlarına karşı yapılan tahminler günden güne bilgisayar ortamına taşınmaktadır. Gelişen bilgisayar bilimi ile bilgisayarlar artık hesap makinesi görevi yerine sanal beyin rolünü üstlenmektedir. Pek çok örnekte senelerce bu konuda çalışmış, uzmanlık alanı finansal bilimler olan bir çok daha iyi yönlendirmeler yapmaktadır. Bunun nedeni insan hatasının olmaması, tamamen nesnel ve mantiki yargılarla hareket edilmesi, insan beyninin işleyemeyeceği kadar fazla verinin incelenebiliyor olması olarak sıralanabilir.

Bu projede 2005 – 2015 yılları arasındaki ihracat ithalat, tüfe, TCMB (Türkiye Cumhuriyeti Merkez Bankası) gecelik faiz, Amerikan merkez bankası (FED) 10 yıllık faiz oranları verileri, Dolar/Euro paritesi ve politik istikrar indeksi nitelik (attribute) olarak kullanarak günlük doların Türk lirasına karşı değerini belirten kur tahmini yapılmaya çalışılmıştır. Tezin ilerleyen kısımlarında ayrıntılı bir şekilde anlatılacağı gibi bu veriler önce veri madenciliğine uygun hale getirilmek amacıyla bir dizi ön işleme (Pre-processing) işleminden geçirilmiştir.

İlgili verilen dallanmaya uygun yapısına bakarak en uygun veri madenciliği metodunun rasgele orman (Random Forest) algoritması olduğu görüldüğünden projede bu algoritma kullanılmıştır.

Veri madenciliği gibi geniş bir konunun tüm yanları ile anlatılması sadece bir bitirme tezi ile mümkün olmayacağından bu çalışmada uygulanan yöntemler ayrıntıları ile irdelenmekte birlikte projeye doğrudan ilişkisi olmayan konulara olabildiğinde yer verilmeye çalışılmıştır.

II. PROJENİN TANIMI VE PLANI

Projenin teorik altyapısının iyi oluşması açısından literatür çalışmasına son derece önem verilmiştir. Bu bilgiler iyiye oturmada ilgili veri toplama ve madencilik yapma aşamasına geçilmemiş, konunun finans sektörüyle ilgili olmasından dolayı finansla ilgili gerekli araştırmalar yapılmıştır. Projenin zamana yayımı aşağıdaki şekilde gösterilmiştir.

İş Paketi	Görev Tanımları	ZAMANLANDIRMA ÇİZELGESİ (Hafta)												
		1	2	3	4	5	6	7	8	9	10	11	12	13
1.Proje Ön Hazırlık Aşaması	Proje Planlaması	■												
	Literatür Taraması		■	■										
2. Kaynak Okuma ve Teorik Temel	Veri Madenciliği Temelleri				■									
	Veri Madenciliği Algoritmaları					■	■							
	Web Mining Temelleri							■	■					
3. Uygulama	Verinin Kullanabilirliği ve İşlenmesi									■				
	Knime ile Verinin Toplanması										■			
	Knime ile Veri Uygulamaları											■		
	Proje Son Kontrol ve Düzenleme												■	
	Kitap Basım ve CD Teslim													■

Şekil 2.1 : Proje planlamasının Gantt diagramıyla gösterimi

III. KURAMSAL BİLGİLER

3.1 Veri Nedir ?

Veri madenciliği uygulamalarında halk dilinin aksine bilgi ve veri aynı anlamda kullanılmamaktadır. Elimizdeki veriden (data) işe yarar elzem veriye ulaşmayı 4 basamağa ayırabiliriz. Bunlar sırasıyla veri (data), malumat (information), bilgi (knowledge), irfan/bilgelik (wisdom) olarak verilebilir. Sıralamada ilerledikçe elimizdeki bilgi yığınları giderek azalmakla birlikte

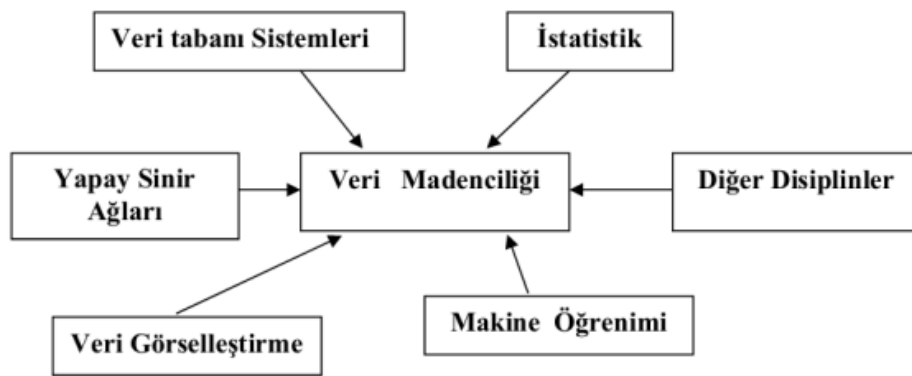
- **Veri (Data) :** Hiçbir seçki işlemine tutulmamış, üzerinde değişiklik yapılmamış, yazılı, görsel, analog ve dijital işlenmeye hazır yapıdır. Örneğin bulunduğumuz odanın sıcaklığı, okulumuzun öğrenci veritabanı, hava basıncı buna örnektir.
- **Malumat (Information) :** Malumat ise bu verini işlenmiş hali denilebilir. Örneğin bir marketin günde ne kadar satarsa zarar edeceği, ne kadar satış yaparsa yeni şube açabileceği bir bilgidir.
- **Bilgi (Knowledge) :** Bilgi ise malumatın çıkarım yapılması şeklinde düşünülebilir. Örneğin; bir futbolcunun kaç maç oynarsa ikramiye alacağı bir malumatsa, bu futbolcunun başarılı sayılıp sayılmayacağı bir bilgidir. Çünkü bu veri, o seneki ligin durumu, oynanan takımın durumu, atılan gol ve pas sayısı gibi birçok veriyle ilişkilidir.
- **Bilgelik (Wisdom) :** Bilgelik, üstü kapalı birçok verinin sonuç olarak çıkarımı şeklinde düşünülebilir. Örneğin; doktorluk vasfı altında daha öncelik hasta deneyimleri, teorik ve uygulamalı verinin bilindiği anlamı gelmektedir.

3.2 Veri Madenciliği Nedir ?

Yazının icadından çok daha öncesinden beri insanlık olarak devamlı artan bilgi birikimimiz türümüzün sosyal evrimini ilerletmesinde en önemli etkenlerden biri olmuştur. Telgraf ve telefonu saymazsak 20.yüzyıla kadar kağıtlar ve tabletler üzerinde olan verilerimiz, 2.Dünya savaşı sırasında elektronik olarak saklanması veya hitlerin yaptığı gibi tüm evrene radyo yayını ile gönderilmesi ya düşman karşı bir övünç meselesiydi yada istihbarat örgütlerinin elindeki pahalı oyuncaklardı. Tüm bu olaylar insanlığa şunu gösterdi; elimizdeki bilgileri artık 0 ve 1'ler şeklinde güvenli ve hızlı bir şekilde erişebilmeyi başarmıştık.

İşte tam burada, daha çok 20.yüzyılın son çeyreğinde başlayan yükselen veri miktarının nasıl depolanacağı bu verilerinden nasıl önemli verilerin çıkarılabileceği yüksek sesle sorulmaya başlandı. Önceleri çok daha dağınık biçimde depolanan veriler

1970 yılında Dr. Edgar Frank Codd'ın ilişkisel veritabanı ile ilgili makalesini yayınlanması ile hala bir çok üniversitede ders olarak okutulan, hala etkisini sürdüren bir modern veri teorisinin ortaya atıldı[4]. En çok duyduğumuz MySQL, MSSQL, Oracle gibi ilişkisel veritabanları (RDBMS) bu temeller üzerine kuruludur. Daha sonraları OLAP (Online Transaction Processing) ve OLTP kavramları ortaya çıkmıştır. Kısaca değinmek gerekirse OLTP verilerin sürekli değiştiği, OLAP ise raporlama ve karar destek yapıları için kullanılan veri yapılarıdır[5]. Örneğin en ünlü ERP uygulaması SAP OLAP tabanlıdır. Tüm bu yeniliklere rağmen artan veri yığınları arasından gerekli bilginin ayıklanması veri miktarının üstel şekilde artması sonucunda giderek zorlaşmıştır. Bilgisayarların hayatımızın içine daha çok girmesi nedeniyle bu sorun sadece bir bilgisayar bilimi sorunu değil finans sektöründen tutunda sağlık sektörüne kadar çok alanlı (multidisipliner) sorun sorun olmuştur[9].



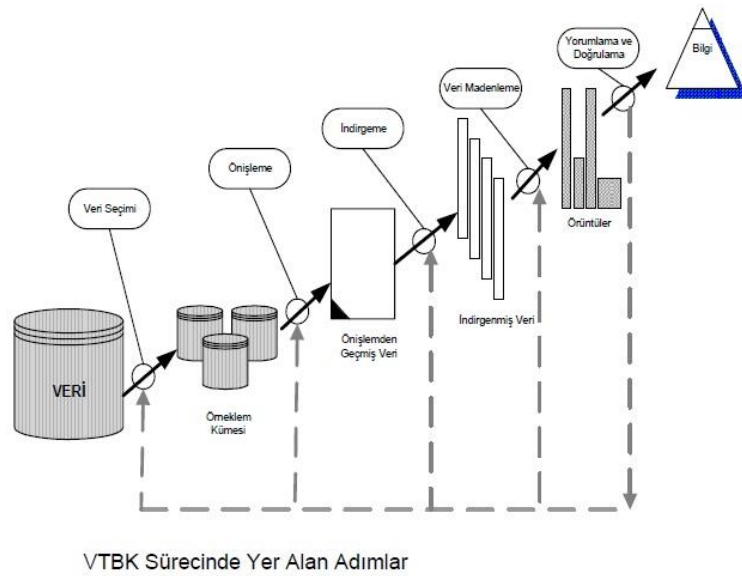
Şekil 3.1 : Veri madenciliğinin diğer disiplinlerle bağlantısı[7]

Bu sorunu çözen ise veri madenciliği uygulamaları olmuştur. Türkiye Bilimler Akademisinin (TÜBA), Türkçe Bilim Sözlüğünde “veri madenciliği” anahtar kelimesi ile arama yapıldığında karşımıza “İstatistik yöntemlere dayanarak büyük veri hacimleri, veritabanları, ürün sunucuları içinde saklı kalmış yönsemeleri, anlamlı bilgileri ve ilişkileri açığa çıkarmaya yönelik irdeleme ve değerlendirme çalışması.” tanımı çıkmaktadır[6]. Literatürde KDD (Knowledge Discovery in Databases) olan Türkçeye VTBK (Veri Tabanı Bilgi Keşfi) olarak geçmiş bu tanım kısaca karmaşık verilerden değerli verilere giden yolu olarak anlatılmaktadır. Bir VTBK süreci 4 adımdan oluşmaktadır.

- **Veri Seçimi (Data Selection)** : Elde edinilmek çıkarımın oluşması için sorulan soruya veya sorulara cevap verebilecek veri grubunun seçilmesi işlemidir[3].
- **Veri Önleme (Data Preprocessing)** : Veri üzerinde madencilik yapmak amacıyla verideki hatalı, yanlış veya eksik verilerin düzeltilmesine işlenmesi olarak söylenebilir. Genel kanının aksine her zaman eksik veriyi

silme doğru olmayabilir[3].

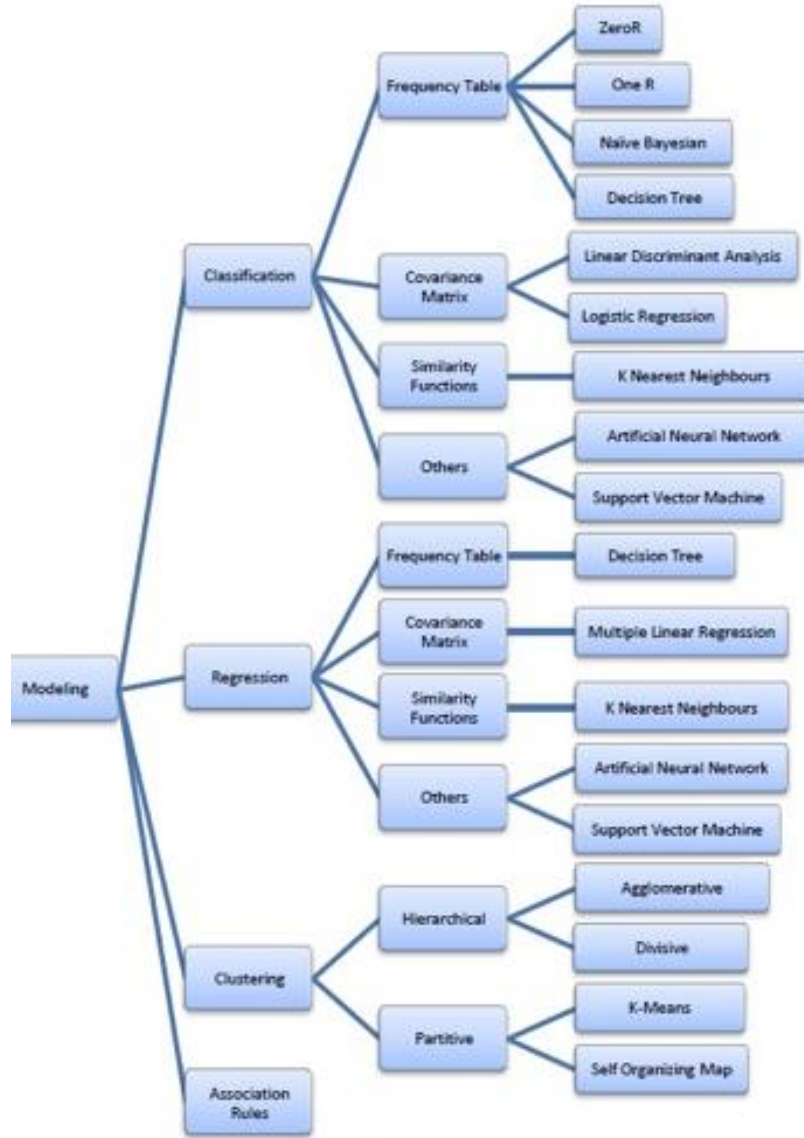
- **Veri Dönüştürme / İndirgeme (Data Transformation) :** Veri madenciliğinde kullanacak verinin çeşitli teknik nedenlerle küçültülmesi ile daha hızlı çıkarım yapmayı sağlamayı amaçlanmaktadır[3].
- **Veri Madenciliği (Data Mining) :** Bu aşamada ise ilerleyen bölümlerde anlatılacak olan metotlar kullanılarak yorumlamaya uygun elzem verinin çıkartılmasıdır[3].
- **Veri Yorumlama (Data Interpretation) :** Veri madenciliği sonucunda çıkan şablonun (pattern) anlamının ve doğruluğun yorumlanması aşamasındadır. Şu söylenmelidir ki her zaman bir hata payı olacağından en mantıklı yorumu yaparken işleme süresi doğruluk oranı nitelik sayısı gibi etkenler göz önünde bulundurulmalıdır[3].



Şekil 3.2 : VTBK süreci[8]

3.3 Veri Madenciliği Metotları

Veri madenciliği metotlarının temel amacı bilgiler arasındaki temel bağıntı ve korelasyonu bularak çeşitli şablonlar üretmektir. Bağıntı birden fazla olay arasında doğrudan bulunan ilişkidir. Örneğin; koştüğümüz için kalbimiz hızlı atması bir bağıntı olmasına karşın kalbimiz çok hızlı attığı için kalp krizi geçirmemiz korelasyondur. Unutulmamalıdır ki, tüm veriler üzerinde doğru olacak herhangi bir metot yoktur ve her metodun mutlak hata payı vardır. Sadece bir yapı tek başına kullanılmak zorunda değildir örneğin karar ağacı yapısı ile ilkelleme bir arada karar ağacı ilkellemesi (Decision Tree Regression) yapısını oluşturabilir. Bu çalışmada projeye bağlı kalarak teorik bilgi vermek açısından en çok kullanılan ilkelleme (regression), en yakın komşu (k-nearest neighbors), karar ağaçları (decision tree), destek vektör makineleri (support vector machine) yöntemleri anlatılmıştır.



Şekil 3.3 : Veri madenciliği metotlarının sınıflandırılması.

Veri madenciliği metotlarını ikiye ayırabiliriz bunlar;

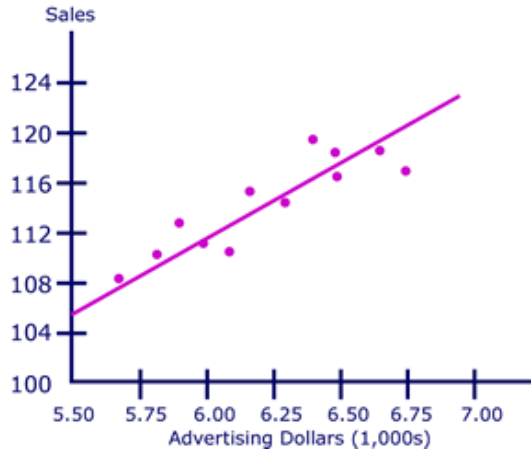
- **Gözetimli Öğrenme (Supervised)** : Daha önceden edinilen tecrübeler ışığında verinin dağılıcağı doğru sınıf sayısı biliniyor, yani elimizde örnek bir veri yapısı duruyor. Bu metot tipinde varsayılan olarak örnek verinin %60'ı öğrenme kümesi (Traning Set), %40'ı ise sınama kümesi (Test Set) olarak kullanılır.
- **Gözetimsiz Öğrenme (Unsupervised)** : Bir deneme ve sınama verisinin kullanılmadığı, önceden küme sayısının bilinmediği durumlarda çıkarım yapmak için kullanılır. Genelde gözetimli öğrenmeye göre uzun sürer çünkü istenilen bilgiye ulaşmak için çok fazla denemeye yapabilir.

3.3.1 İkkelleme (Regression)

Basit olarak anlatacak olursak elimizdeki karmaşık verileri daha basit doğrulara indirgenmesidir. Temelde iki farklı ikelleme tipi vardır. Gözetimli öğrenme yapar.

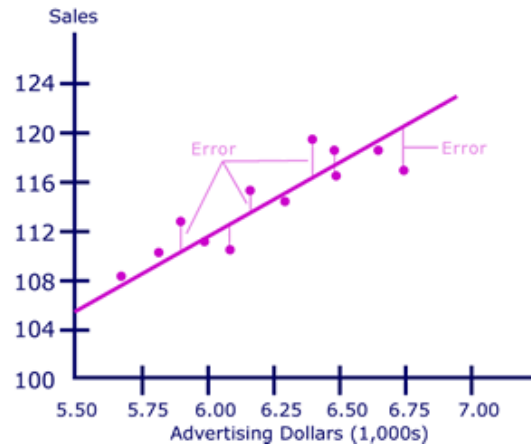
- Doğrusal İkkelleme (Linear Regression)

İki boyutlu uzayda X ve Y eksenini arasındaki korelasyonu doğrusal bir fonksiyona benzeterek verilerin en düşük hatayla en yüksek verimi almasını sağlar ancak basit korelasyonlar için uygunken karmaşık veriler üzerinde denenmesi olumsuz sonuçlara yol açabilir.



Şekil 3.3.1 : İkkelleme yapılmış satış/reklam verisi[11]

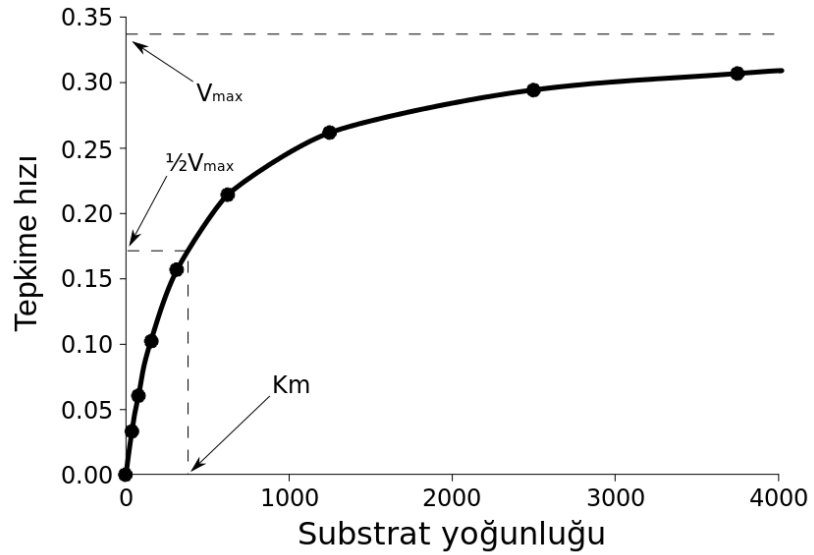
Veri tabanındaki her bir kayıt oklid uzayından bir x,y (a,b ikilisi de denilebilir) konumunda bir nokta ile temsil edilir. Bu verilen tüm noktaları en az sapma ile tüm yapıyı temsil edilebilecek bir $y = ax + c$ doğrusu çizilmesi hedeflenmektedir. Bu her a,b ikilisinin oluşturduğumuz doğru denklemine ya çok yakın olması hatta direkt sağlaması demektir. Aşağıda modelimizin oluşturduğu doğruya uzak olan ve dolayısıyla yanlış olan verileri temsil eden noktalar gösterilmiştir.



Şekil 3.3.2 : Modeldeki hataların gösterimi[11]

- **Doğrusal Olmayan İkelleme (Non-Linear Regression)**


Elimizdeki verilerden doğrusal korelasyonlar bulunmadığında kullanılır. Doğrusal ikellemedeki tüm kurallar aynen geçerlidir anca bu kes ortaya çıkan en az ikinci dereceden bir denklem çıkar. Bu ax^2+bx+c şeklinde ifade edilebilir. Örneğin Ph değerini gösteren bir model veya biyolojideki substrat yoğunluğu buna örnek gösterilebilir.



Şekil 3.3.3 : Örnek doğrusal olmayan model

3.3.2 En Yakın Komşu (K-Nearest Neighbors)

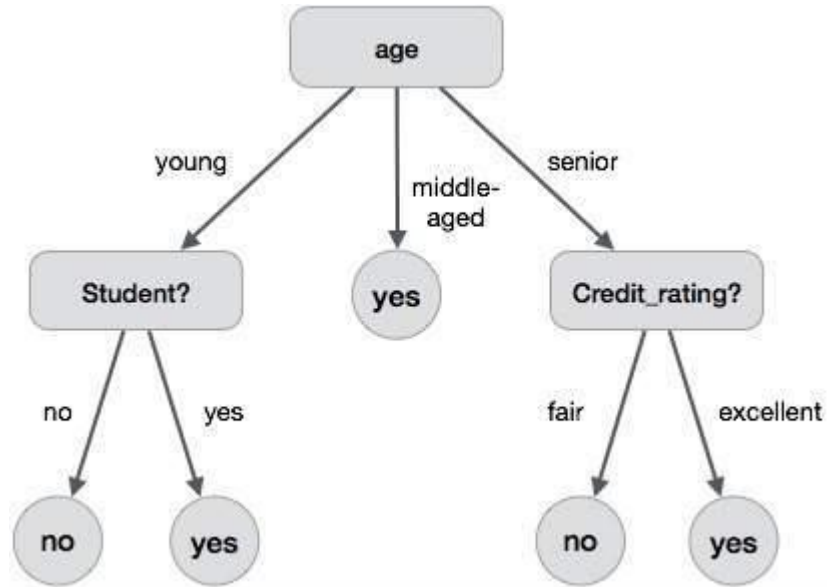
İki boyutlu uzaydan belirlenmiş verilerimizin yeni bir veri geldiğinde nasıl sınıflandırılacağını belirleyen metottur. K değeri kadar elemanla kendini sınıflandırılır. Örneğin k değeri 3 ise oklid uzaklığı en yakın olan 3 noktayla kendini sınıflandırır. Gözetimli öğrenme yapar.



Şekil 3.3.4 : KNN çalışması

3.3.3 Karar Ağacı (Decision Tree)


Karmaşık verilerde sıkça kullanılan bir metottur. Yapısı ağaç (tree), düğüm veya dallardan (node) oluşur. Mantığı ise karar vermeye en çok etki eden niteliklerin kök dallarda (root node) bulundurup, karmaşıklığı (entropy) en aza indirmektir. Bunu bilgi kazancı (data gain) ile yapmaktadır. Bir çok alt algoritması olmakla birlikte bu projede ise random forest algoritması kullanılacağından, o anlatılmıştır.



Şekil 3.3.5 : Karar ağacı örneği [12]

- **Random Forest** : Tek bir karar ağacı üretmek yerine bir çok karar ağacı üretilip bunlardan en iyi modeli kullanmaya dayanan bir algoritmadır.

3.3.4 Destek Vektör Makinesi (Support Vector Machine)



Şekil 3.3.6 : Örnek hyperplane ayrılması

SVM, özet olarak anlatmak gerekirse koordinat düzleminde nokta olarak belirtilmiş verilerin arasındaki boşluklardan en uygun ve eşit derecede uzak şekilde bölünerek oluşturulmasına dayanan bir metottür. Gözetimli bir öğrenmedir. Şekil 3.3.6 da ortada gözükken ve iki veri grubunu ayıran çizgiye hyperplane denir. Temel amaç hyperplanein iki gruba eşit mesafede uzak olmasıdır.

3.4 Projedeki Nitelikler (Attributes)

Projedeki tüm veriler 2005 – 2015 yılları arasını kapsamaktadır. İlgili veriler ön işleme sokulmuştur. Bu veriler proje dosyaları içinde eksiksiz verilmiştir.

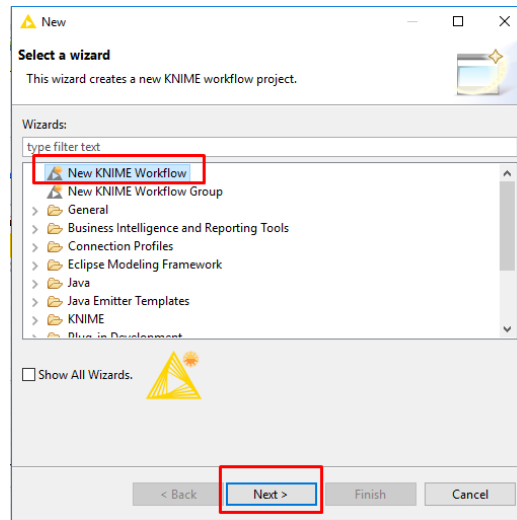
- **ABD Dolar Kuru :** Bu nitelik Türkiye Cumhuriyeti merkez bankası elektronik veri dağıtım sisteminden elde edilen verilere dayanmaktadır. Veriler projede kullanılan öğrenme kümesi (train set) ve modelin sınamasını yapma amacıyla kullanılmıştır[13].
- **İhracat İthalat Verileri :** Bu nitelik TÜİK verilerine dayanmaktadır. Gelecek çıkarımı yapmak için kullanılmıştır[14].
- **Tüketici Fiyat Endeksi (TÜFE) :** Enflasyonun doğrudan belirleyicisidir. Tüketici ürünlerin fiyatının ne kadar arttığını gösterir. TÜİK verilerinden faydalanılmıştır[15].
- **TCMB Gecelik Faiz Oranı :** Merkez bankasının yabancı para kurları üzerindeki en büyük silahlarından biridir. Bu veri sitedeki html dökümünden elde edilmiştir[16].
- **Politik İstikrar İndeksi:** Dünyadaki tüm ülkelerin siyasal kaos durumuna göre bir sıralamaya tabi tutulması ile oluşturulan veridir. Bu projde dünya bankası verileri göz önünde bulundurulmuştur[17].
- **FED 10 Yıllık Faiz :** FED, yani Amerikan merkez bankasının belirlediği tüm dünya para kurlarını etkileyen faiz oranıdır. ABD de kuru etkileyen ana faizdir[18].
- **Dolar/Euro Paritesi :** Dolar ve EURO kurları arasındaki bağıntıyı belirleyen parametredir[19].

IV. TASARIM, GERÇEKLEME

4.1 KNIME


Knime açık kaynak veri madenciliği uygulamasıdır. Java tabanlı olduğundan çapraz platform desteği vardır. Üzerinde bulunan node çeşitliliği ücretsiz olması tercih sebeplerindedir. Projede aynı modüllerin defalarca anlatılması önlenmek amacıyla her modül en az bir kez anlatılarak geçilmiştir. İstenildiği takdirde proje dosyasından tüm modüllerin içeriği gözlemlenebilir.

KNIME programında veri madenciliği uygulaması yapmak için öncelikle yeni bir proje açmamız gerekir. Bunun için “File > New” yoluna tıklanır. Burada “New KNIME Workflow” seçili iken “Next” butonuna basıp ilerliyoruz.



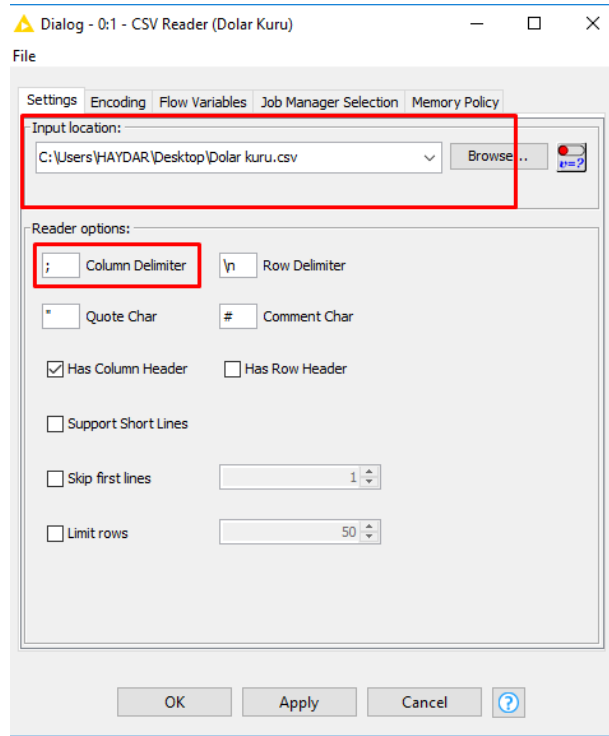
Şekil 4.1 : Yeni proje açılması

Daha sonra “Name of the workflow to create” kısmına “Bitirme Projesi” girilir ve Finish butonuna basılır. İstenildiği takdirde “Destination of new workflow” kısmında varsayılan çalışma şemasının yeri değiştirilebilir.




Şekil 4.2 : Çalışma alanı oluşturulması

Knime’da tüm Nodelar (Modüllerde denilebilir) “Node repository” penceresi altında bulunmaktadır. Gereksiz tekrarı önlemek amacı ile adı verilen nodun buradan eklendiği bilinmelidir. İlk nitelik olarak dolar kurunu ekleyeceğiz. Elimizdeki dolar kuru .csv formatında olduğu için Node repository penceresi altından CSV Reader nodu ekran sürüklenerek çalışma şemasına eklenir.



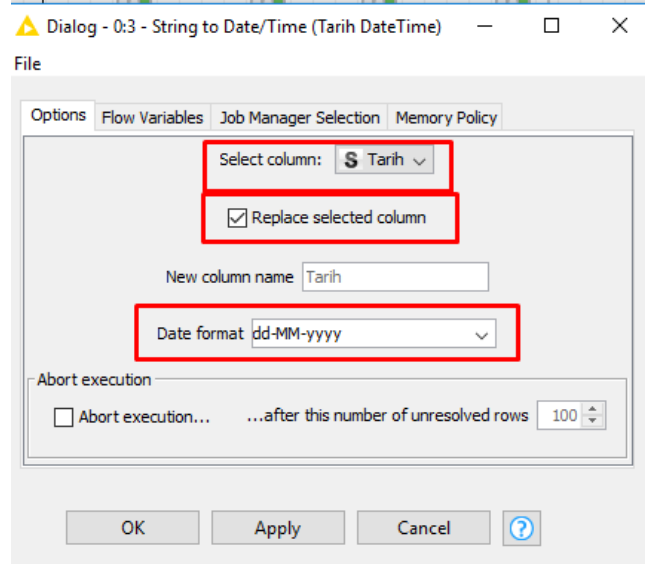
Şekil 4.3 : CSV Reader Ayarları

CSV Reader nodumuzun üzerine gelip sağ tıklayıp daha sonra “Configure” seçeneğine tıklanır. “Browse” butonuna tıklayarak Input Location kısmına dosyamızın adresi girilir. “Column delimiter” kısmına ise tablomuzdaki sütunları ayırmak için “;” karakteri girilir. Apply butonuna basılır. Daha sonra şekil 4.4 de gösterilen Run butonuna basılır. Run sadece o node’u çalıştırırken “Run All” şemadaki tüm nodeları çalıştırır. Her node sonrası bu yapılmalıdır, gereksiz tekrarı önlemek adına bundan sonra bu işlemin her nodedan sonra basıldığı kabul edilmiştir.



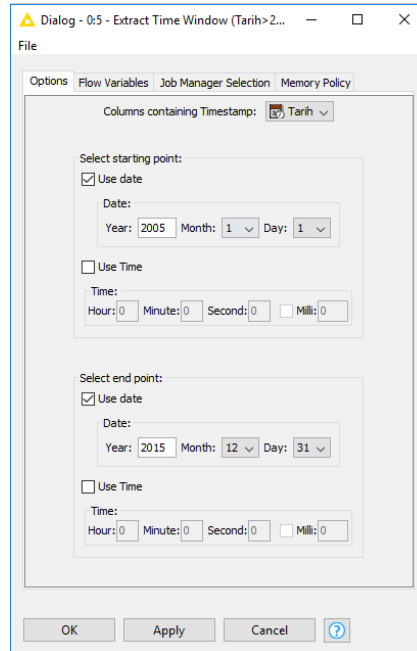
Şekil 4.4 : Sırasıyla Run ve Run All seçeneği

Çalışma şemasına (WorkFlow) “String to Date/Time” nodunu eklenip ve bir önceki CSV Reader noduna ekledikten sonra sağ tık configure kısmında aşağıdaki ayarları yapıldı. Bu node string veri türündeki veriyi datetime veri türüne çevrildi.



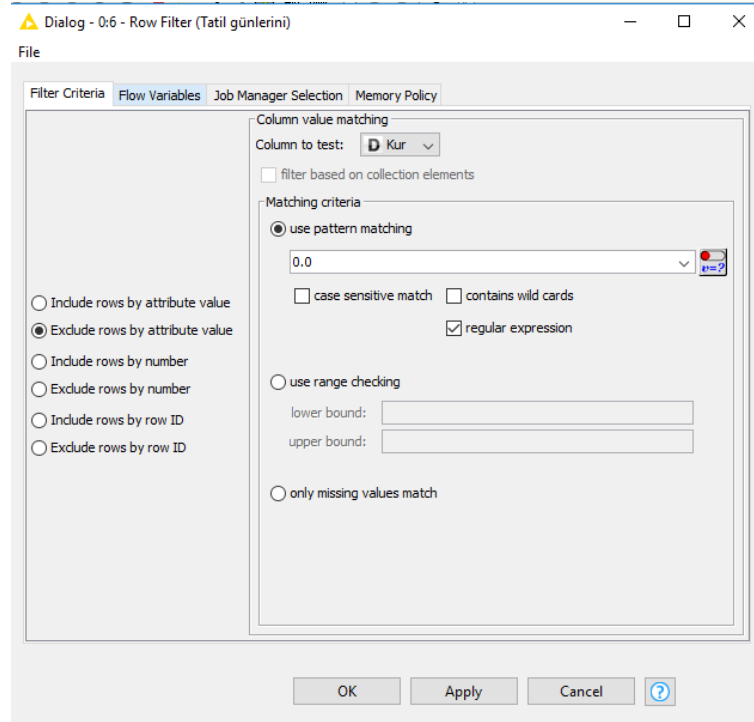
Şekil 4.5: String to Data/Time Ayarları

Şimdi de Extract Time Windows nodunu ekliyoruz. Bu node da verilerimizi zaman aralığında filtre edildi. Önceki nodu ile birleştirildi. Sağ tık > configure dedikten sonra aşağıdaki ayarları yapıyoruz ve Apply butonuna basıyoruz.



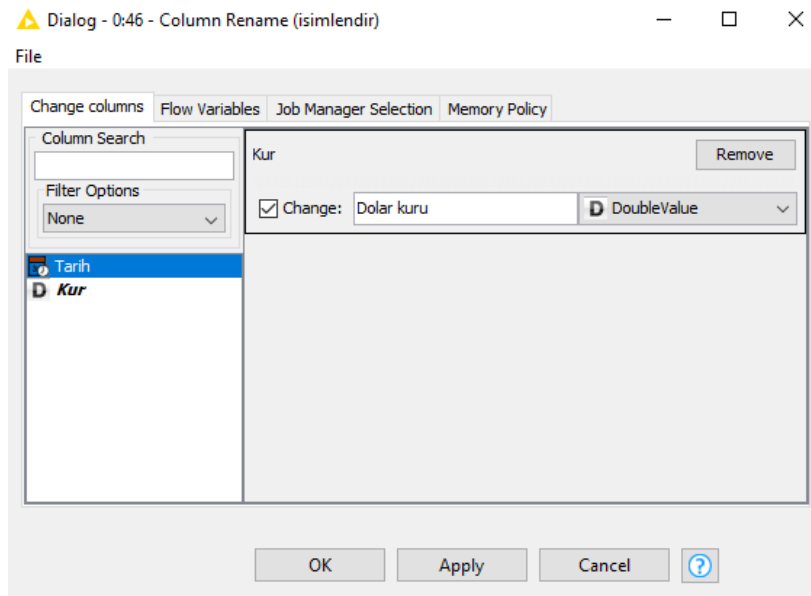
Şekil 4.6 : Extract Time Window Ayarları

Çalışma alanımıza Row Filter nodumuzu ekliyoruz. Önceki node ile bağliyoruz. Bu node istenilen değere sahip satırı silmek için kullanılır. Burada verimizdeki tatil günleri boş girilen kur verisini tablodan çıkartmıştır.



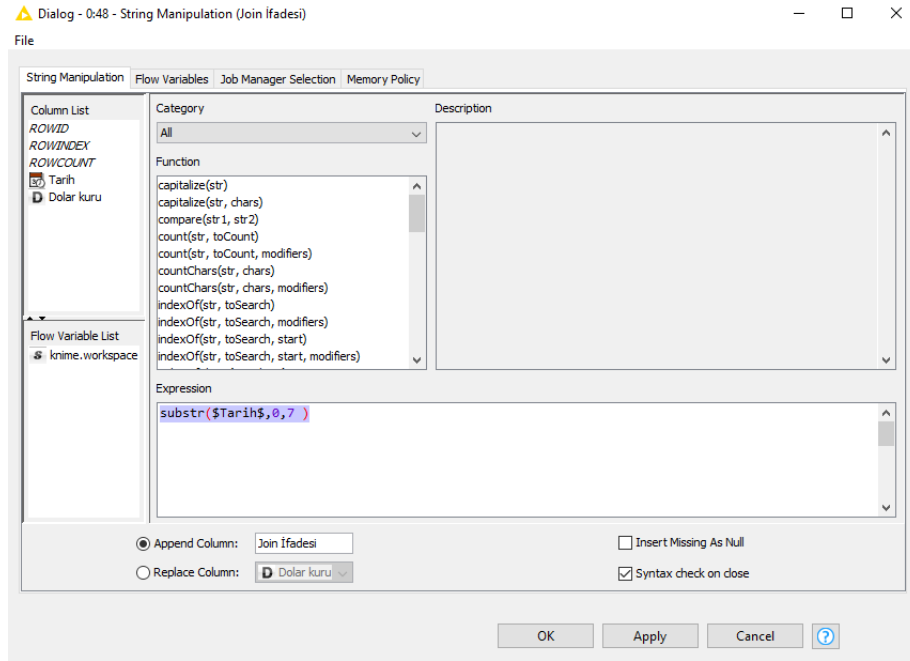
Şekil 4.7 : Row Filter Ayarları

Column Rename nodunu ekleyip önceki node'a bağlanmıştır. Kur kısmına tıklanılıp, çift aşağıdaki şekilde görüldüğü gibi "Dolar kuru" olarak sütün adı değiştirilmiştir.



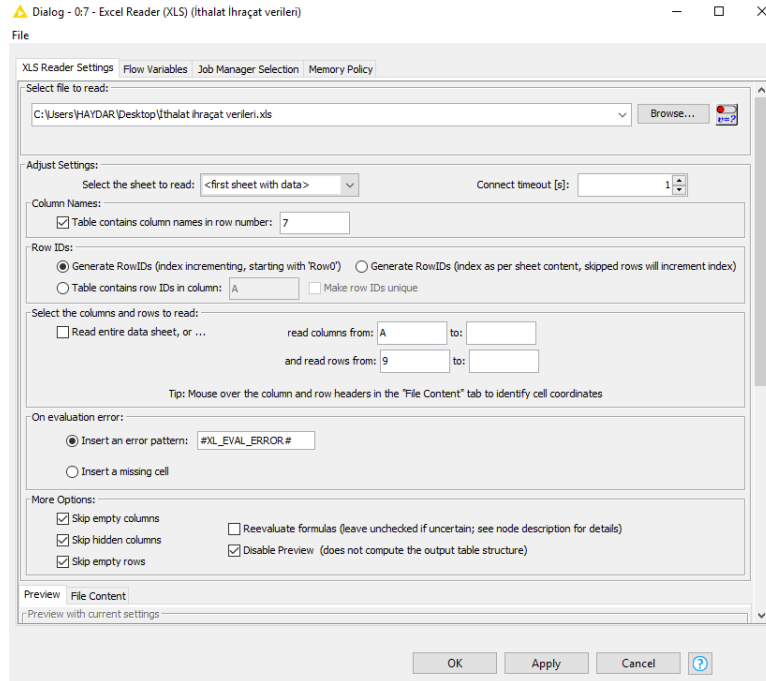
Şekil 4.8 : Column Rename Ayarları

String Manipulation nodunu ekleyip önceki node ile bağlıyoruz. Tablolarımızı birleştirmek için join ifadesi olarak tarih sütününden yıl+ay şekilde veri çıkarmak için kullanılmıştır. Sağ tık > configure tıkladıktan sonra aşağıdaki ayarlar yapılmıştır.



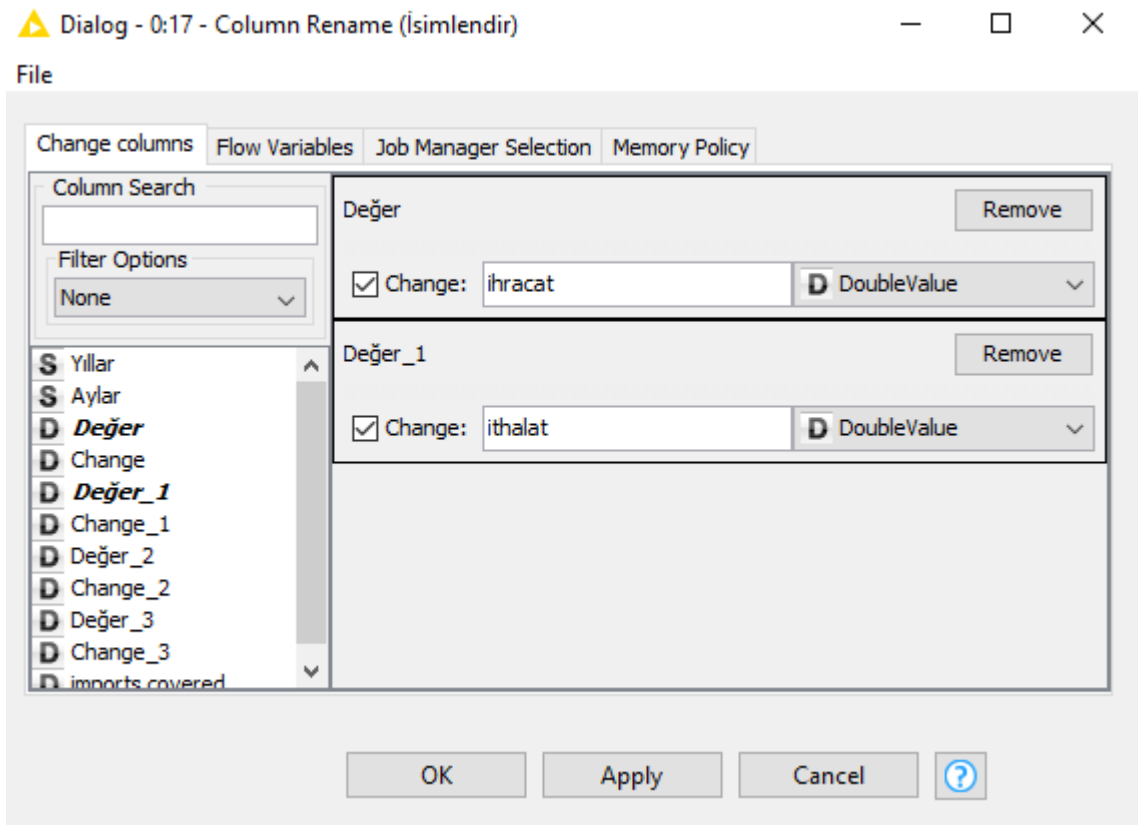
Şekil 4.9 : String Manipulation Ayarları

Projeye Excel Reader(XLS) node'unu eklerken Browse butonuyla verinin bulunduğu XLS dosyası seçilmiştir. Columns Names kısmına 7 girilerek sütun isimlerinin 7 satırdan başladığı belirtilmiştir. A9'dan veriyi okumaya başlaması belirtilmiştir.



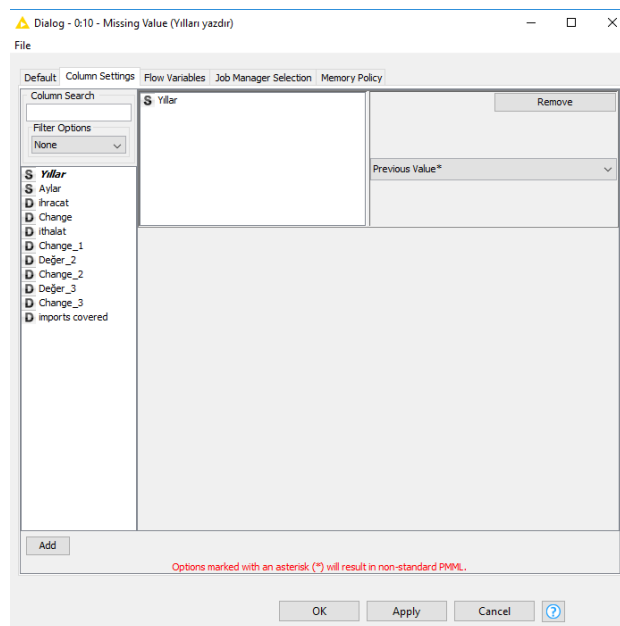
Şekil 4.10 : Excel Reader Ayarları

Column Rename nodu eklenilmiştir. İhracat ve ithalat verileri aşağıdaki gibi isimlendirilmiştir.



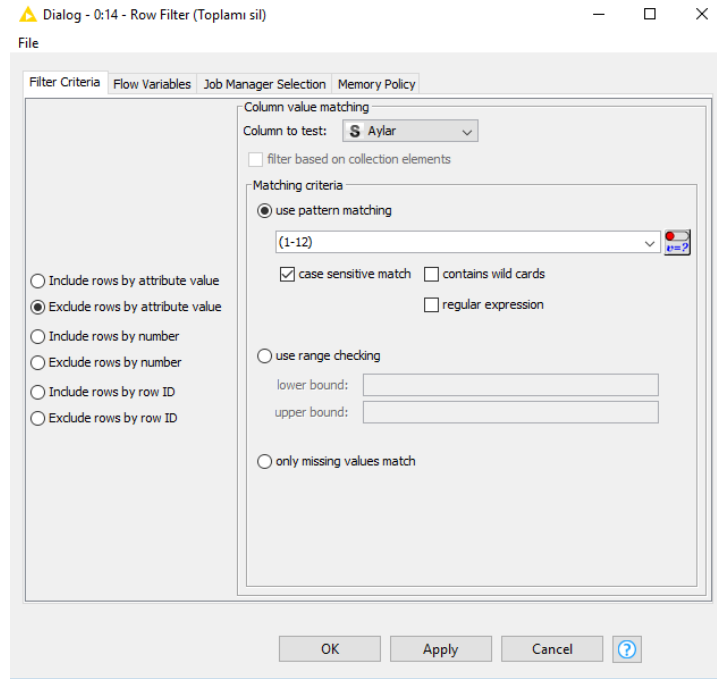
Şekil 4.11 : Column Rename Ayarları

Missing Value node'ünü projeye eklenip, bir önceki node 'a balanıp, yıllara çift tıklandıktan sonra Previous Value seçeneğine tıklanarak boş olan değerlere bir önceki değerleri girilmesi sağlanmıştır. Son olarak Apply butonuna basılmıştır.



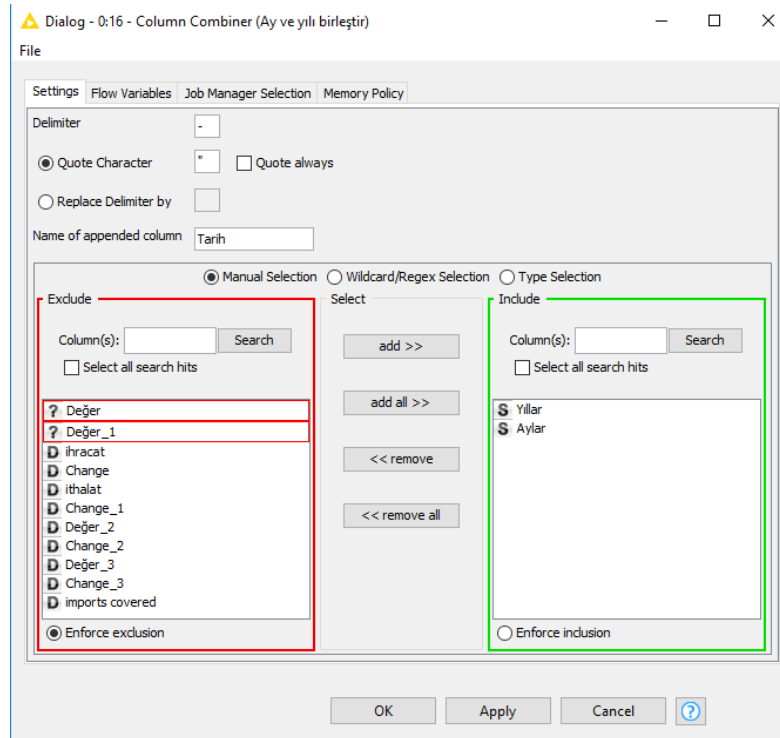
Şekil 4.12 : Missing Value Ayarları

Row filter projeye eklenip bir önceki node ile bağlanılmıştır. Aşağıdaki ayarlarda görebileceği gibi aylar niteliğindeki hücrede “(1-12)” verisi olan yerler silinmiştir. Daha sonra Apply butonuna basılmıştır.



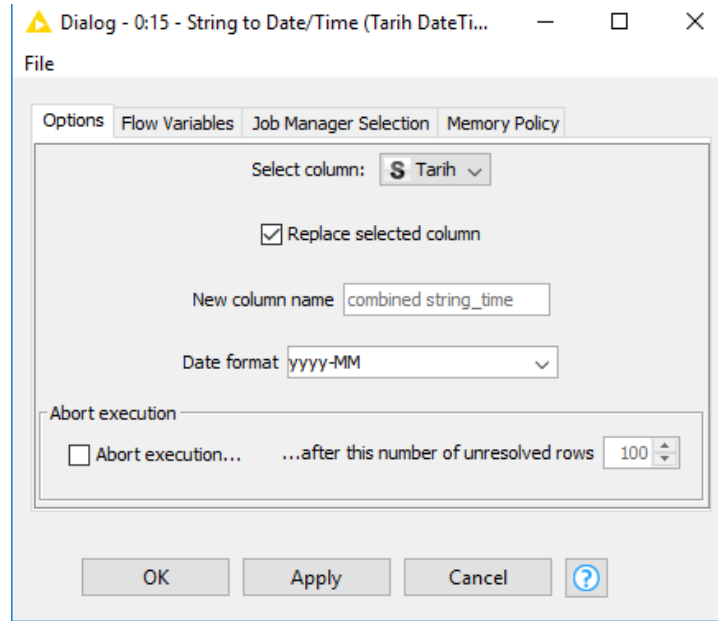
Şekil 4.13 : Row Filter Ayarları

Column Combiner node’u eklenip önceki noda bağlandıktan sonra aylar ve yıllar kısmının üzerine basılıp add butonuna basılıp Apply denilmiştir.



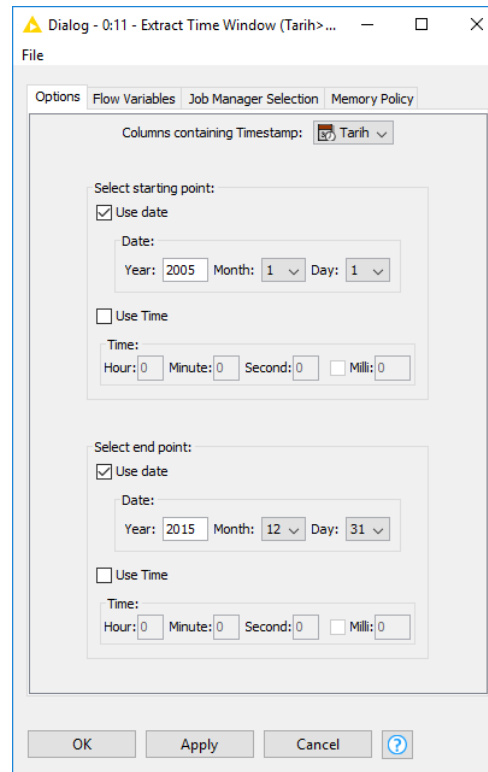
Şekil 4.13 : Column Combiner

String to Date/Time nodu eklenip önceki node'a bağlandıktan sonra aşağıdaki ayarlar yapılır Apply butonuna basılmıştır.



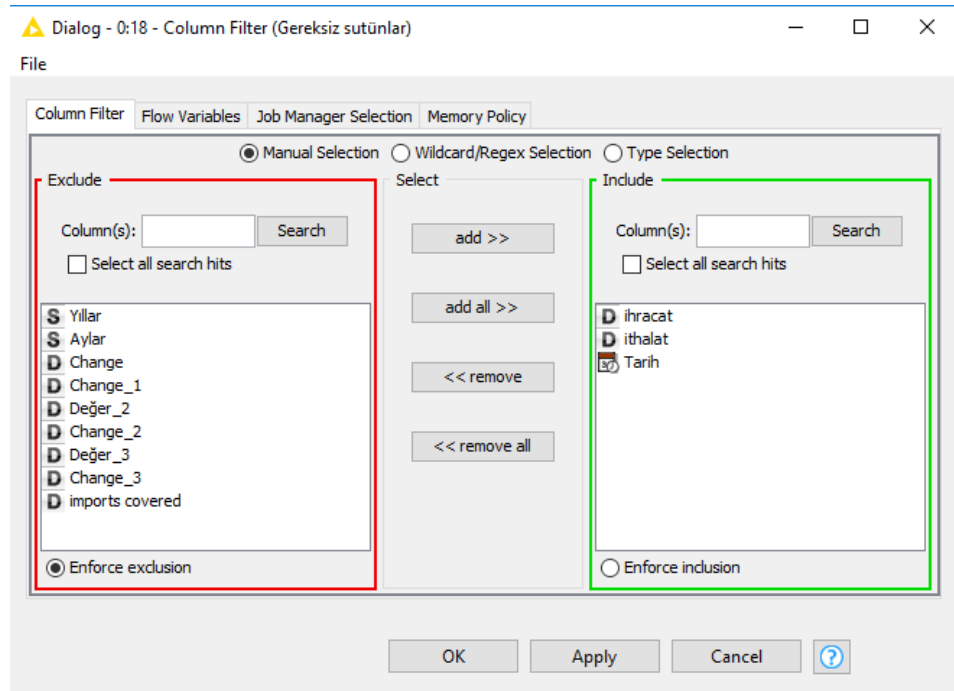
Şekil 4.14 : String to Date/Time Ayarları

Extract Time Windows nodu eklenip önceki node'a bağlandıktan sonra 2005 -2015 tarihleri filtrelenmek için aşağıdaki ayarlar yapılmıştır. Apply butonuna basılmıştır.



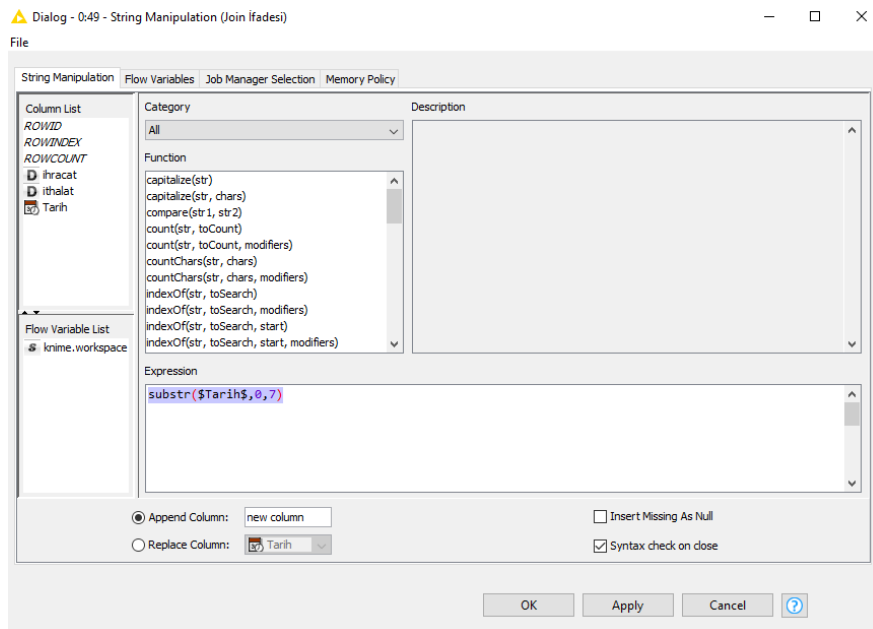
Şekil 4.15 : Extract Time Window

Column filter nodu eklenip, önceki nodela bağlandıktan sonra ihracat, ithalat ve tarih nitelikleri üzerine basıldıktan sonra Add butonuna basılmıştır. Daha sonra ise Apply butonuna basılmıştır.



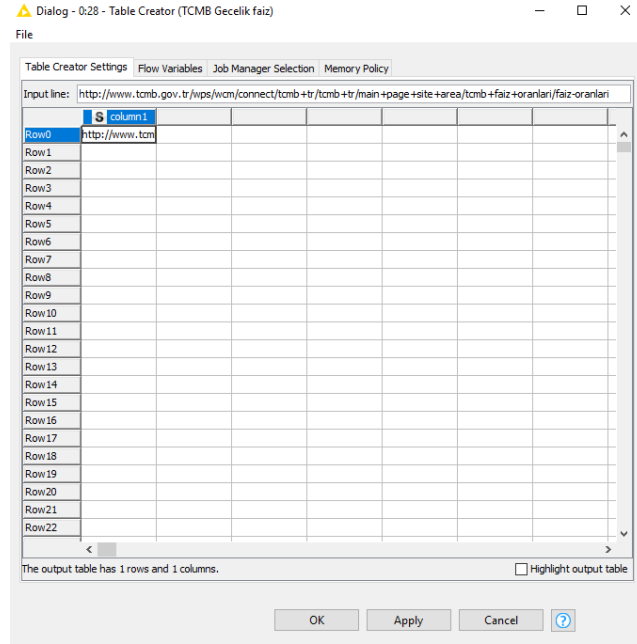
Şekil 4.16 : Column Filter Ayarları

String Manipulation nodu eklenip önceki node'a bağlandıktan sonra aşağıdaki ayarlar yapılmıştır.



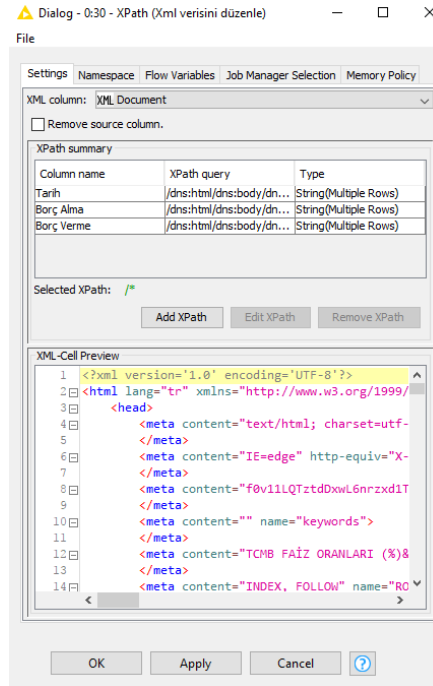
Şekil 4.17: String Manipulation Ayarları

Öncelikle projeye Table Creator Nodu eklenip veri kaynağının internet adresi girilmiştir. Daha sonra Apply butonuna basılmıştır.



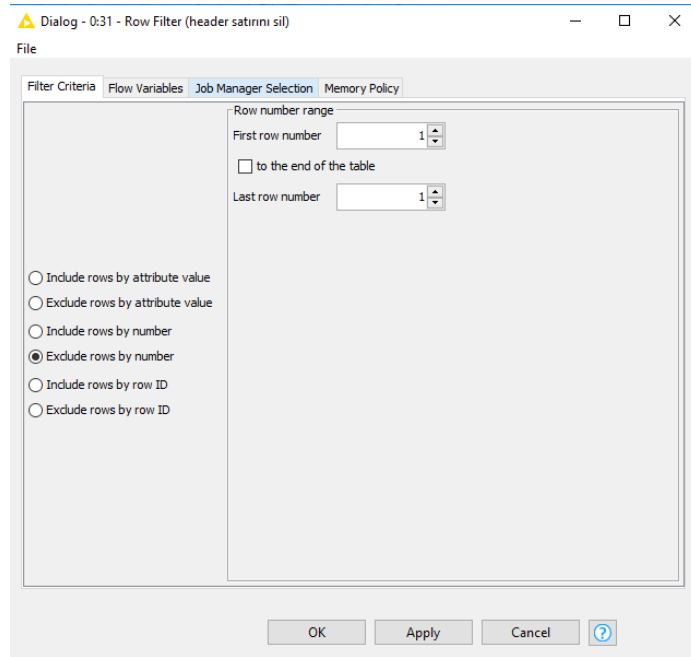
Şekil 4.18 : Table Creator Ayarları

Projeye HtmlParser node'u eklenip önceki node'a bağlanmıştır. Sonrasında Xpath ile xml verisini çekmek için Sağ tık > configure denildikten sonra aşağıdaki gibi ayarlar yapılır, Apply butonuna basılmıştır.



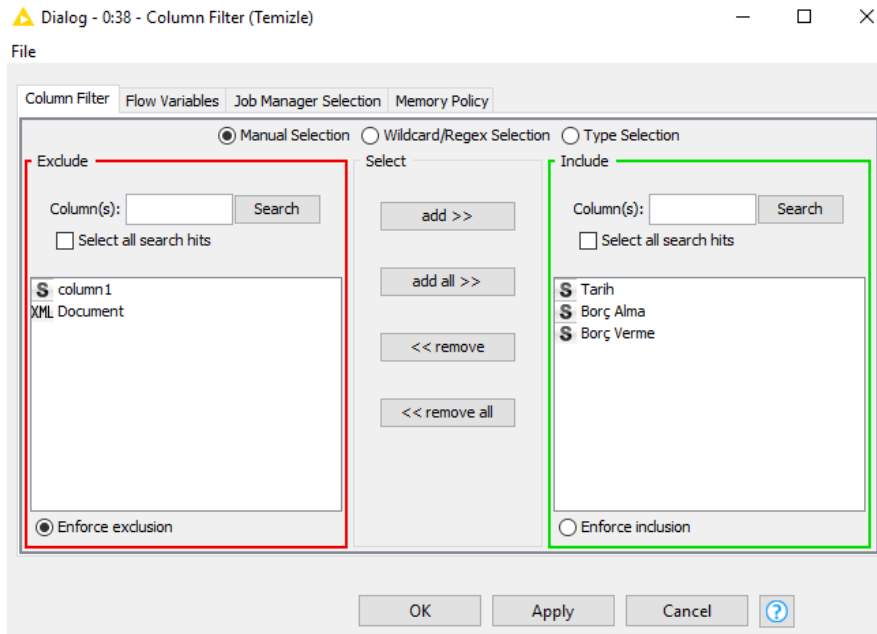
Şekil 4.19 : XPath Ayarları

Projeye Row Filter Node'u eklenip, Sağ tık > configure tıklanıp şekildeki gibi 1,1 değerleri verilip Apply denilmiştir. Böylece tablodaki ilk satır silinecektir.



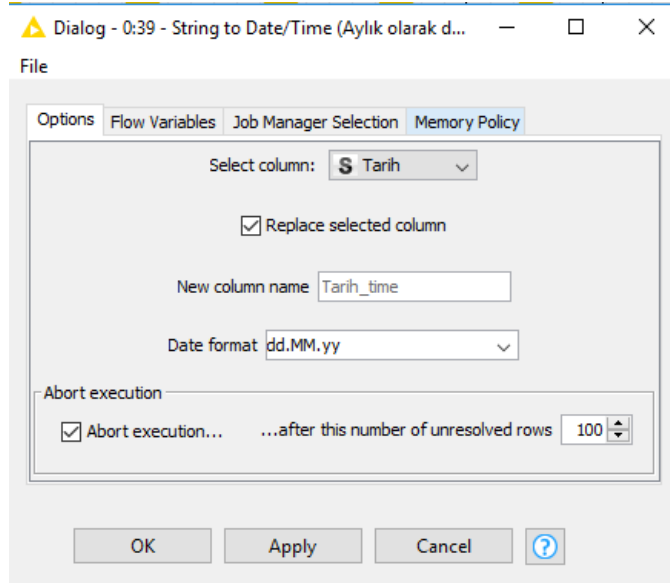
Şekil 4.20 : Row Filter Ayarları

Projeye Column Filter node'u eklenip, öncelikli node bağlanmıştır. Sağ tık > configure tıklanıp, Tarih, Borç Alma, Borç Verme nitelikleri işaretlenip Add ve Apply butonuna basılmıştır.



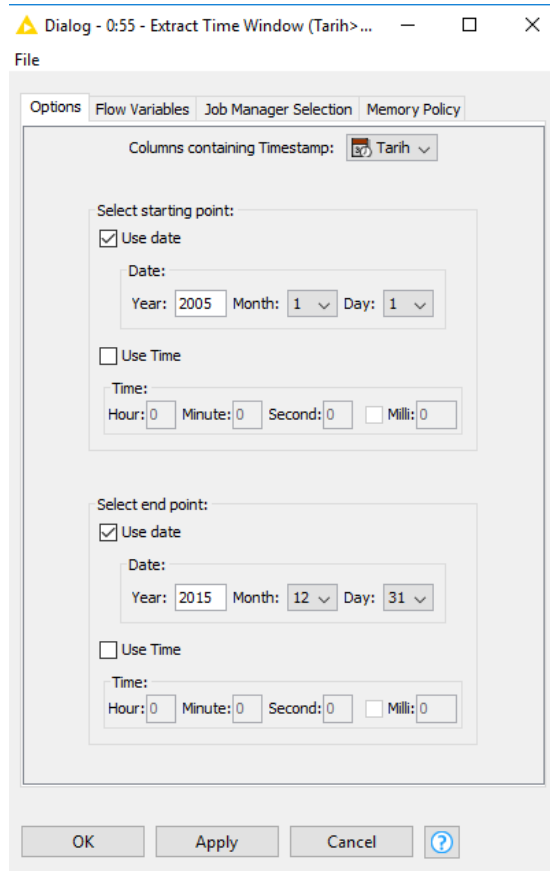
Şekil 4.21 : Column Filter Ayarları

Projeye String to Date/Time nodu eklenip önceki node'a bağlandıktan sonra sağ tık > configure tıklanıp, aşağıdaki ayarlar yapıldıktan sonra Apply butonuna basılmıştır.



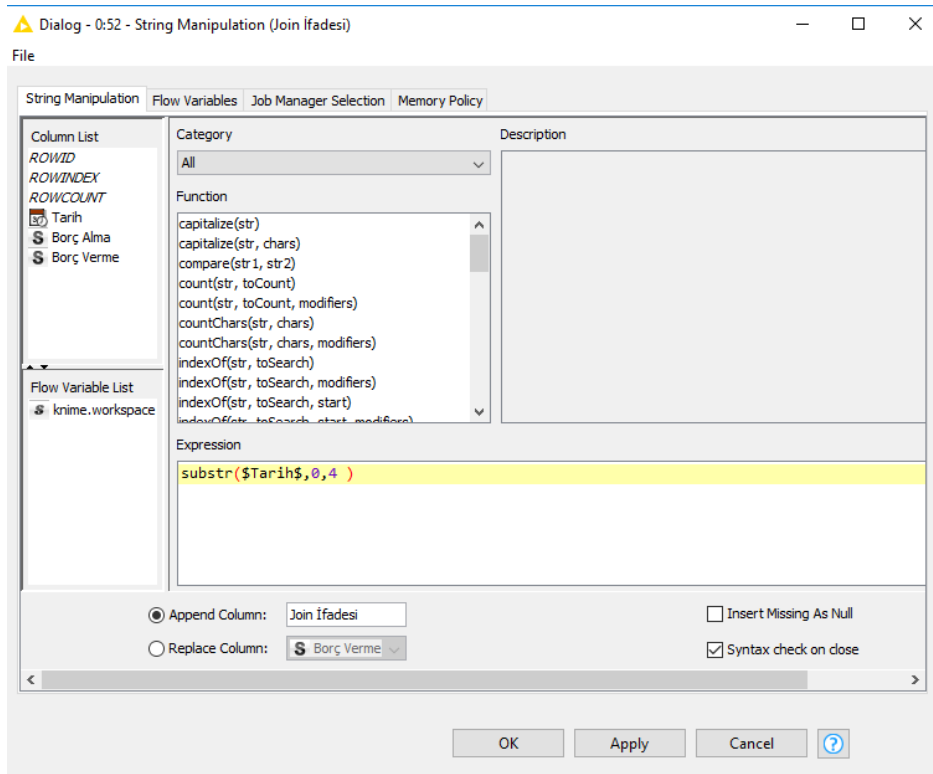
Şekil 4.22 : String to Date/Time Ayarları

Projeye Extact Time Window nodu eklenip önceki node'a bağlandıktan sonra sağ tık > configure tıklanıp, aşağıdaki ayarlar yapıldıktan sonra Apply butonuna basılmıştır.



Şekil 4.23 : Extract Time Window Ayarları

Projeye String Manipulation nodu eklenip önceki node'a bağlandıktan sonra sağ tık > configure tıklanıp, aşağıdaki ayarlar yapıldıktan sonra Apply butonuna basılmıştır.



Şekil 4.24 : String Manipulation Ayarları

Yukarıda gözlemlenebildiği gibi niteliklerimiz ön işleme (Preprocessing) tabii tutulmuştur. Bu işlemlerden sonra group by ve joinerlarla birleştirip tek bir tablo haline getirilmiştir. Projede Polinomsal ilkelleme (polynomial regression) ve random forest algoritmaları denenmiştir. Uygunluk açısından random forest tree algoritması seçilmiştir.

Polinomsal regressionu denemek için projeye Polynomial Regression Learner nodu eklenmiştir. Bu çalışma şeması CD'den "poly" isminde bulunabilir. Node çalıştırdıktan sonra node üzerine sağ tıklayıp "Data With Training Error" da tıklanılmıştır. Çıkan ekranda Prediction sütününe önce sol tıklayıp "sort descending" daha sonra sağ tıklayıp Available Renderers > Percentage yoluna tıklanılmıştır. Çıkan sonuç sonraki sayfadaki gibidir.

▲ Data with training error - 0:66 - Polynomial Regression Learner (Node 66)

File

Row ID	Tarih	D Mean(D...	D First(thr...	D First(th...	D Mean(T...	D Mean(B...	D Mean(B...	D sra	D VALUE ...	D DEXUSEU	D PolyRe...	D Prediction Error
Row2264_Ro...	30.Dec.2013	2.16	13,174,857.46	23,139,030....	0.599	4.036	7.607	11.848	2.902	1.382	1.856	30.43%
Row374_Row...	26.Jun.2006	1.693	7,815,434.622	12,465,724....	0.774	15.625	19.292	27.053	5.106	1.402	2.918	29.18%
Row375_Row...	27.Jun.2006	1.684	7,815,434.622	12,465,724....	0.774	15.625	19.292	27.053	5.106	1.259	1.401	28.29%
Row2265_Ro...	31.Dec.2013	2.134	13,174,857.46	23,139,030....	0.599	4.036	7.607	11.848	2.902	1.378	1.86	27.48%
Row373_Row...	23.Jun.2006	1.661	7,815,434.622	12,465,724....	0.774	15.625	19.292	27.053	5.106	1.252	1.402	25.85%
Row935_Row...	10.Sep.2008	1.216	12,793,148....	17,884,561....	0.806	15.937	19.375	18.269	3.686	1.402	1.458	24.16%
Row372_Row...	22.Jun.2006	1.641	7,815,434.622	12,465,724....	0.774	15.625	19.292	27.053	5.106	1.258	1.401	24.05%
Row936_Row...	11.Sep.2008	1.229	12,793,148....	17,884,561....	0.806	15.937	19.375	18.269	3.686	1.394	1.466	23.72%
Row376_Row...	28.Jun.2006	1.637	7,815,434.622	12,465,724....	0.774	15.625	19.292	27.053	5.106	1.253	1.402	23.55%
Row2263_Ro...	27.Dec.2013	2.096	13,174,857.46	23,139,030....	0.599	4.036	7.607	11.848	2.902	1.377	1.861	23.5%
Row934_Row...	09.Sep.2008	1.216	12,793,148....	17,884,561....	0.806	15.937	19.375	18.269	3.686	1.417	1.441	22.55%
Row2259_Ro...	23.Dec.2013	2.089	13,174,857.46	23,139,030....	0.599	4.036	7.607	11.848	2.902	1.37	1.867	22.25%
Row2260_Ro...	24.Dec.2013	2.088	13,174,857.46	23,139,030....	0.599	4.036	7.607	11.848	2.902	1.368	1.869	21.9%
Row929_Row...	02.Sep.2008	1.179	12,793,148....	17,884,561....	0.806	15.937	19.375	18.269	3.686	1.452	1.398	21.89%
Row930_Row...	03.Sep.2008	1.184	12,793,148....	17,884,561....	0.806	15.937	19.375	18.269	3.686	1.449	1.402	21.82%
Row932_Rd	Row929_Row3	Row376_Row560	Row956" (14/2448)	17,884,561....	0.806	15.937	19.375	18.269	3.686	1.427	1.429	21.65%
Row949_Rd...	03.Oct.2008	1.232	9,722,708.79	14,942,454....	0.806	15.937	19.375	18.269	3.814	1.382	1.448	21.63%
Row931_Row...	04.Sep.2008	1.204	12,793,148....	17,884,561....	0.806	15.937	19.375	18.269	3.686	1.436	1.419	21.52%
Row1514_Ro...	07.Jan.2011	1.54	9,551,084.639	16,905,384....	0.839	5	10.75	18.957	3.394	1.294	1.754	21.41%
Row767_Row...	16.Jan.2008	1.145	10,632,207....	16,338,588....	0.806	15.937	19.375	18.269	3.744	1.464	1.356	21.07%
Row1513_Ro...	06.Jan.2011	1.54	9,551,084.639	16,905,384....	0.839	5	10.75	18.957	3.394	1.303	1.75	21.04%
Row933_Row...	08.Sep.2008	1.236	12,793,148....	17,884,561....	0.806	15.937	19.375	18.269	3.686	1.413	1.447	21.04%
Row371_Row...	21.Jun.2006	1.609	7,815,434.622	12,465,724....	0.774	15.625	19.292	27.053	5.106	1.266	1.399	21.01%
Row377_Row...	29.Jun.2006	1.612	7,815,434.622	12,465,724....	0.774	15.625	19.292	27.053	5.106	1.253	1.402	20.98%
Row781_Row...	05.Feb.2008	1.159	11,077,899.12	16,026,520....	0.806	15.937	19.375	18.269	3.738	1.464	1.369	20.98%
Row378_Row...	30.Jun.2006	1.603	7,815,434.622	12,465,724....	0.774	15.625	19.292	27.053	5.106	1.278	1.395	20.79%
Row783_Row...	07.Feb.2008	1.181	11,077,899.12	16,026,520....	0.806	15.937	19.375	18.269	3.738	1.45	1.388	20.74%
Row383_Row...	07.Jul.2006	1.588	7,067,411.479	11,709,384.29	0.774	15.625	19.292	27.053	5.088	1.282	1.382	20.59%
Row782_Row...	06.Feb.2008	1.164	11,077,899.12	16,026,520....	0.806	15.937	19.375	18.269	3.738	1.465	1.368	20.36%
Row2262_Ro...	26.Dec.2013	2.071	13,174,857.46	23,139,030....	0.599	4.036	7.607	11.848	2.902	1.369	1.867	20.35%
Row938_Row...	15.Sep.2008	1.24	12,793,148....	17,884,561....	0.806	15.937	19.375	18.269	3.686	1.417	1.441	20.09%
Row366_Row...	14.Jun.2006	1.601	7,815,434.622	12,465,724....	0.774	15.625	19.292	27.053	5.106	1.263	1.4	20.09%
Row836_Row...	22.Apr.2008	1.308	11,363,963....	17,889,469....	0.806	15.937	19.375	18.269	3.675	1.601	1.108	19.98%
Row1512_Ro...	05.Jan.2011	1.544	9,551,084.639	16,905,384....	0.839	5	10.75	18.957	3.394	1.317	1.743	19.82%
Row762_Row...	09.Jan.2008	1.155	10,632,207....	16,338,588....	0.806	15.937	19.375	18.269	3.744	1.466	1.353	19.77%
Row1515_Ro...	10.Jan.2011	1.557	9,551,084.639	16,905,384....	0.839	5	10.75	18.957	3.394	1.294	1.754	19.71%
Row2284_Ro...	28.Jan.2014	2.343	12,399,761....	19,286,491....	0.659	7.667	11.75	11.905	2.858	1.366	2.147	19.61%
Row1522_Ro...	19.Jan.2011	1.526	9,551,084.639	16,905,384....	0.839	5	10.75	18.957	3.394	1.349	1.721	19.47%
Row760_Row...	07.Jan.2008	1.157	10,632,207....	16,338,588....	0.806	15.937	19.375	18.269	3.744	1.468	1.35	19.31%

Şekil 4.25 : Polynomial Regression Sonuçları

Görüldüğü üzere tahmin hatası %30.43 gibi yüksek bir rakam çıkmaktadır. Verinin bu algoritmaya uygunluğunu tartışmalı hale getirmiştir. Bu yüzden bu node kaldırarak yerine Random Forest Learner (Regression) ve Random Forest Predictor (Regression) nodu eklenip bir birlerine bağlanmıştır. Modeli çalıştırdıktan sonra sütününe önce sol tıklayıp “sort descending” daha sonra sağ tıklayıp Available Renderers > Percentage yoluna tıklanılmıştır. Çıkan sonuç aşağıdaki gibidir.

▲ Prediction output - 0:68 - Random Forest Predictor (Regression) (Tahmin Et)

File

Row ID	Tarih	D Mean(D...	D First(thr...	D First(th...	D Mean(T...	D Mean(B...	D Mean(B...	D sra	D VALUE ...	D DEXUSEU	D Mean(D...	i model c...	D Predicti...	D Prediction (MeanDolar...	
Row965_Row...	27.Oct.2008	1.691	9,722,708.79	14,942,454....	0.806	15.937	19.375	18.269	3.814	1.245	1.521	0.014	37	1.556	1.07%
Row949_Row...	03.Oct.2008	1.232	9,722,708.79	14,942,454....	0.806	15.937	19.375	18.269	3.814	1.382	1.445	0.007	41	1.412	1.05%
Row966_Row...	28.Oct.2008	1.686	9,722,708.79	14,942,454....	0.806	15.937	19.375	18.269	3.814	1.248	1.564	0.011	45	1.569	0.89%
Row2038_Ro...	01.Feb.2013	1.755	12,385,690....	19,395,113....	0.599	4.036	7.607	11.848	1.984	1.369	1.863	0.008	51	1.851	0.76%
Row964_Row...	24.Oct.2008	1.695	9,722,708.79	14,942,454....	0.806	15.937	19.375	18.269	3.814	1.264	1.526	0.003	36	1.559	0.74%
Row2040_Ro...	05.Feb.2013	1.746	12,385,690....	19,395,113....	0.599	4.036	7.607	11.848	1.984	1.357	1.861	0.008	35	1.85	0.7%
Row2039_Ro...	04.Feb.2013	1.746	12,385,690....	19,395,113....	0.599	4.036	7.607	11.848	1.984	1.353	1.856	0.006	40	1.85	0.69%
Row2041_Ro...	06.Feb.2013	1.751	12,385,690....	19,395,113....	0.599	4.036	7.607	11.848	1.984	1.353	1.829	0.007	41	1.85	0.69%
Row2264_Ro...	30.Dec.2013	2.16	13,174,857.46	23,139,030....	0.599	4.036	7.607	11.848	2.902	1.382	1.975	0.004	40	2	0.68%
Row1697_Ro...	27.Sep.2011	1.843	10,750,626....	21,203,687....	0.839	5	10.75	18.957	1.975	1.361	1.721	0.006	33	1.742	0.66%
Row1700_Ro...	30.Sep.2011	1.845	10,750,626....	21,203,687....	0.839	5	10.75	18.957	1.975	1.345	1.737	0.006	32	1.746	0.65%
Row1696_Ro...	26.Sep.2011	1.826	10,750,626....	21,203,687....	0.839	5	10.75	18.957	1.975	1.352	1.731	0.007	32	1.746	0.65%
Row1695_Ro...	23.Sep.2011	1.818	10,750,626....	21,203,687....	0.839	5	10.75	18.957	1.975	1.352	1.741	0.008	40	1.746	0.64%
Row1737_Ro...	25.Nov.2011	1.855	11,078,524....	18,649,309....	0.839	5	10.75	18.957	2.013	1.324	1.739	0.008	24	1.768	0.64%
Row1694_Ro...	22.Sep.2011	1.789	10,750,626....	21,203,687....	0.839	5	10.75	18.957	1.975	1.345	1.75	0.007	39	1.745	0.64%
Row1738_Ro...	28.Nov.2011	1.875	11,078,524....	18,649,309....	0.839	5	10.75	18.957	2.013	1.333	1.757	0.007	37	1.767	0.63%
Row1739_Ro...	29.Nov.2011	1.855	11,078,524....	18,649,309....	0.839	5	10.75	18.957	2.013	1.334	1.741	0.006	28	1.767	0.63%
Row1698_Ro...	28.Sep.2011	1.841	10,750,626....	21,203,687....	0.839	5	10.75	18.957	1.975	1.363	1.728	0.006	34	1.739	0.62%
Row2517_Ro...	02.Jan.2015	2.327	12,301,766.75	16,645,657.05	0.707	7.25	10.75	9.524	1.881	1.202	2.303	0.018	34	2.317	0.62%
Row1735_Ro...	23.Nov.2011	1.833	11,078,524....	18,649,309....	0.839	5	10.75	18.957	2.013	1.335	1.775	0.006	46	1.766	0.62%
Row963_Row...	23.Oct.2008	1.635	9,722,708.79	14,942,454....	0.806	15.937	19.375	18.269	3.814	1.288	1.522	0.007	45	1.536	0.61%
Row967_Row...	30.Oct.2008	1.686	9,722,708.79	14,942,454....	0.806	15.937	19.375	18.269	3.814	1.285	1.521	0.006	33	1.544	0.61%
Row333_Row...	27.Apr.2006	1.322	6,456,090.261	11,587,101....	0.774	15.625	19.292	27.053	4.991	1.252	1.414	0.007	42	1.389	0.6%
Row1699_Ro...	29.Sep.2011	1.837	10,750,626....	21,203,687....	0.839	5	10.75	18.957	1.975	1.364	1.712	0.005	29	1.738	0.6%
Row962_Row...	22.Oct.2008	1.524	9,722,708.79	14,942,454....	0.806	15.937	19.375	18.269	3.814	1.284	1.551	0.008	45	1.543	0.59%
Row1688_Ro...	12.Sep.2011	1.767	10,750,626....	21,203,687....	0.839										

V. SONUÇ ve ÖNERİLER

Elde edilen sonuçlara göre dolar kuru tahmini gibi karmaşık bir uygulamada polinomsal ilkellemenin yeterli olmadığı görülmüştür. Bu çalışmada görüldüğü gibi karar ağaçları uygulaması projede büyük farkla daha isabetli nitelik çıkarımı yapmaktadır. Rasgele karar ağacı en fazla %1.07 sapma ile sonuç bulurken polinomsal ilkelleme ise %30.43 sapma verdiğiinden böyle bir sapmanın toleransa tabii tutulması doğru olmayacaktır ancak hız açısından polinomsal ilkelleme, rastgele karar ağacı gibi ağaç dalına özel hesap yapmadığından daha hızlı çalıştığı söylenebilir.

Elde edilen sonuçların daha verimli yorumlana bilinmesi için ilgili verilerimizin 2005-2015 tarihleri arasından çok daha uzun dönemlere göre uyarlanması faydalı olabilir ancak veri miktarı uzadıkça işlenen veriye bağlı olmak üzere işlem süresi artacaktır. Bu nedenle en uygun dönemlerin bulunup, buna göre bir veri kümesi hazırlanması için iktisatçılarla disiplinler arası bir proje yapılabilir.

KAYNAKLAR

- [1] UNHRC, "Promotion and protection of all human rights, civil, political, economic, social and cultural rights, including the right to development." p. 4.
- [2] IBM. "What is big data ? ," 2017,
<https://www01.ibm.com/software/data/bigdata/what-is-big-data.html>
- [3] Ş. E. ŞEKER, "İş Zekası ve Veri Madenciliği (WEKA ile)," İstanbul, Cinius Yayınları, 2013.
- [4] Codd, Edgar F. "A relational model of data for large shared data banks." Communications of the ACM 13.6 (1970): 377-387.
- [5] ŞENTÜRK, Aysan. Veri Madenciliği Kavram ve Teknikler. Baskı., Bursa, 2006.
- [6] TÜBA, "Türkçe Bilim Terimleri Sözlüğü", 2017, <http://www.tubaterim.gov.tr>
- [7] Mustafa AKGÜL. "Nedir bu veri madenciliği ? ", 2017,
<https://akgulmustafa.wordpress.com/2015/03/01/nedir-bu-veri-madenciligi/>
- [8] Hayri SEVER ve Buket OĞUZ. "Veri Yapıları ve Algoritmalar", 2017,
<https://akagun.wordpress.com/bilisim-teknolojileri/2-hafta/>
- [9] Witten, Ian H., et al. Data Mining: Practical machine learning tools and techniques. Morgan Kaufmann, 2016.
- [10] Columbia University. "Statistical Sampling and Regression: Simple Linear Regression", 2017, http://ci.columbia.edu/ci/premba_test/c0331/s7/s7_6.html
- [11] Burton DeWilde." Classification of Hand-written Digits (3)", 2017,
<http://bdewilde.github.io/blog/blogger/2012/10/26/classification-of-hand-written-digits-3/>
- [12] Tutorialspoint," Data Mining - Decision Tree Induction", 2017,
https://www.tutorialspoint.com/data_mining/dm_dti.htm
- [13] TCMB. "EVDS: Dolar verileri ", 2017, [http://evds.tcmb.gov.tr/cgi-bin/famecgi?cgi=\\$ozetweb&DIL=TR&ARAVERIGRUP=bie_dkdovizgn.db](http://evds.tcmb.gov.tr/cgi-bin/famecgi?cgi=$ozetweb&DIL=TR&ARAVERIGRUP=bie_dkdovizgn.db)
- [14] TÜİK. "Yıllara Göre Dış Ticaret", 2017,
http://www.tuik.gov.tr/PreIstatistikTablo.do?istab_id=621
- [15] TÜİK. "Tüketici Fiyat Endeksi (2003=100)", 2017,
<https://biruni.tuik.gov.tr/medas/?kn=84&locale=tr>
- [16] TCMB. "TCMB Faiz Oranları (%) Gecelik (O/N)", 2017,
<http://www.tcmb.gov.tr/wps/wcm/connect/tcmb+tr/tcmb+tr/main+page+site+area/tcmb+faiz+oranlari/faiz-oranlari>
- [17] World Bank. "The Worldwide Governance Indicators (WGI) project", 2017,
<http://info.worldbank.org/governance/wgi/index.aspx#home>
- [18] FED. "10-Year Treasury Constant Maturity Rate", 2017,
<https://fred.stlouisfed.org/series/DGS10>

[19] FRED Economic Data. “U.S. / Euro Foreign Exchange Rate”, 2017, <https://fred.stlouisfed.org/series/DEXUSEU>

ÖZGEÇMİŞ

İlköğretimime 2003 yılında İstanbul Beyoğlu Pirireis ilköğretim okulunda başladım. 7.sınıftan sonra İstanbul Sancaktepe Küçük Ülkü ilköğretim okulunda devam ederek okulumu bitirdim. Liseye Sancaktepe 75.Yıl DMO Anadolu Teknik Lisesinde gittim ve bölüm olarak veritabanı programcılığı seçtim daha sonra Marmara Üniversitesi Teknik Bilimler Meslek Yüksek Okulu Bilgisayar Programcılığına yerleştim.