

MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE UÇUŞ FİYATLARININ TAHMİNİ

PREDICTING FLIGHT PRICES WITH MACHINE LEARNING METHODS

Mustafa Berk KELEŞ 

Makine Öğrenmesi Uzmanı, Enuygun.com İnternet Bilgi Hizmetleri Teknoloji ve Ticaret A.Ş. AR-GE Merkezi, mustafa.keles@enuygun.com, İstanbul/Türkiye

Aytürk KELEŞ 

Doç. Dr., Ağrı İbrahim Çeçen Üniversitesi, Eğitim Fakültesi, Bilgisayar ve Öğretim Teknolojileri Eğitimi Bölümü, ayturkk@hotmail.com, Ağrı/Türkiye

Ali KELEŞ 

Doç. Dr., Ağrı İbrahim Çeçen Üniversitesi, Eğitim Fakültesi, Bilgisayar ve Öğretim Teknolojileri Eğitimi Bölümü, alakmus@hotmail.com, Ağrı/Türkiye

ABSTRACT

Machine learning is an important area of Artificial Intelligence technologies. Today, thanks to this technology, machines can be successfully trained for difficult tasks in many different areas. This study focuses on machine learning methods and applications that will provide for learning airline price changes gradually from past flight patterns to predict future prices. Flight prices vary greatly depending on airlines' policies, holidays, student mobility, number of remaining seats, months and days, even hours. Considering this situation along with the competition factor and revenue maximization, it is a very difficult task for airline companies to determine ticket prices under the influence of many factors in the most appropriate way. Especially ensemble learning algorithms and many algorithms such as Support Vector Machines, Random Forest, Gradient Boosting, K-Nearest Neighborhood algorithms are used either alone or together to accomplish this difficult task. In this study, machine learning applications developed for flight price prediction were investigated and these applications were analyzed in detail in terms of the method, data set and application performances used. As a result, it is seen that ensemble machine learning models combining strengths (by compensating weaknesses) of multiple sub-models are more successful in predicting flight prices. With the knowledge and experiences obtained from this study, new models that can be used for flight price prediction by using ensemble learning algorithms have been developed within the scope of the "Flight Prices Predictor" project carried out by the ENUYGUN.COM R&D Research Center.

Keywords: Machine Learning, Artificial Intelligence, Ensemble Algorithms, Flight Price, Prediction

ÖZET

Makine öğrenmesi, Yapay Zekâ teknolojilerinin önemli bir alanıdır. Bugün bu teknoloji sayesinde makineler birbirinden farklı pek çok alandaki zorlu görevler için başarılı bir şekilde eğitilebilmektedir. Bu çalışma havayolu fiyat değişikliklerini geçmiş uçuş örüntülerinden aşamalı olarak öğrenerek gelecekteki fiyatları tahmin etmeye olanak sağlayacak makine öğrenmesi yöntemlerine ve uygulamalarına odaklanmaktadır. Uçuş fiyatları havayolu şirketlerinin politikalarına, tatillere, öğrenci hareketliliğine, kalan koltuk sayısına, aylara, günlere, hatta saatlere göre bile büyük değişiklik göstermektedir. Bu durumla birlikte rekabet faktörü ve gelir maksimizasyonu da dikkate alındığında havayolu şirketlerinin pek çok faktörün etkisindeki bilet fiyatlarını en uygun şekilde belirlemesi oldukça zor bir görevdir. Başta topluluk öğrenme algoritmaları olmak üzere Destek Vektör Makineleri (Support Vector Machine), Rastsal Orman, Gradyan Artırım, K-En Yakın Komşuluk algoritmaları gibi pek çok algoritma ya tek başına ya da birlikte bu zor görevi başarmak için kullanılmaktadır. Bu çalışmada uçuş fiyatı tahmini için geliştirilen makine öğrenmesi uygulamaları araştırılmış ve bu uygulamalar kullanılan yöntem, veri seti ve uygulama performansları açısından detaylı bir şekilde analiz edilmiştir. Sonuç olarak uçuş fiyatı tahmininde, makine öğrenmesi

modellerinin oluşturduğu topluluklar birden fazla alt modelin güçlü yönlerini (zayıf yönlerini telafi ederek) birleştirerek daha başarılı oldukları görülmektedir. Bu çalışmadan elde edilen bilgi ve tecrübe ile ENUYGUN.COM Ar-Ge Araştırma Merkezi tarafından yürütülmekte olan “Flight Prices Predictor” projesi kapsamında topluluk öğrenme algoritmaları kullanılmış ve uçuş fiyatı tahmininde kullanılabilecek yeni modeller geliştirilmiştir.

Anahtar Kelimeler: Makine Öğrenmesi, Yapay Zekâ, Topluluk Algoritmaları, Uçuş Bileti, Tahmin

1. GİRİŞ

Makine Öğrenmesi, veriden beslenen bir sisteme açık bir şekilde programlanmadan insana benzer bir şekilde otomatik olarak deneyimlerden öğrenme yeteneği kazandıran etkili bir yakay zekâ uygulamasıdır. Pek çok alanda başarılı bir şekilde kullanılmaktadır. Ama özellikle belirsizliğin daha çok olduğu özel alanlardaki sorunların çözümünde tercih edilmektedir. Örneğin benzer belirtileri gösteren ayırt edilmesi güç hastalıkların bir birinden ayrılması, borsada hisse senetlerinin değişken hareketlerinin tahmini, istenmeyen e-postaların filtrelenmesi ve müşteri deneyimlerinden geleceğe dönük seyahat tercihlerinin tahmin edilmesi gibi pek çok konuda uygulanmaktadır. Bu çalışmada, fiyatı belirleyen değişkenler arasındaki ilişkileri mevcut uçuş bilgilerinden öğrenerek bilet fiyatlarını tahmin edilebilen makine öğrenmesi yöntemlerine ve uygulamalarına yer verilmiştir.

Bu alandaki çalışmalar detaylı bir şekilde incelendiğinde uçuş biletlerinin tahmini için genellikle çevrimiçi seyahat acentalarından elde edilen uçuş bilgilerinden farklı özellikler çıkarılarak veri setleri oluşturulduğu görülmektedir. Bu veri setlerinde aktarmalı/aktarmasız, ulusal/uluslararası, tekli ve çoklu rotalar olmak üzere özellikle uçuştan önceki belli bir zaman dilimini kapsayan pek çok uçuş bilgisi yer almaktadır. Araştırmacılar en düşük (minumum) uçuş fiyatını veya belli bir tarihteki bilet fiyatını en iyi şekilde tahmin etmeye odaklanmıştır. Bunu gerçekleştirmek için makine öğrenmesi algoritmalarını tek olarak, birkaç algoritmayı bir arada veya topluluk öğrenmesi algoritmalarını kullanmışlardır.

2. MATERYAL ve YÖNTEM

Bugün pek çok hava yoluna ait uçuşlar seyahat siteleri aracılığı ile çevrimiçi olarak satışa sunulmaktadır. Söz konusu siteler farklı hava yollarına ait uçuş biletlerini en cazip şekilde müşterilerine sunabilmek, daha fazla müşteri çekebilmek ve satışlarını arttırabilmek için çaba sarfetmektedir. Şirketler bunu gerçekleştirmek için Ar-Ge çalışmalarında çağımızın en güçlü teknolojilerinden biri olan Yapay Zekâyâ odaklanmış durumdadır. Bu konuyla ilgili en çarpıcı örnek Hopper adlı şirket üzerinden verilebilir. Cambridge merkezli çevrimiçi seyahat acentası olan Hopper, geliştirdiği mobil YZ uygulaması ile uçuş ve otel fiyatlarını tahmin edebilmekte ve kullanıcılarına en uygun rezervasyon süresi ve alternatif seyahat teklifleri hakkında kişiselleştirilmiş öneriler sunabilmektedir. 2015’de tanıtımını yaptığı YZ destekli mobil uygulama bugüne kadar 600 milyon dolardan fazla değerde uçuş satmış ve günlük yaklaşık 1,5 milyon dolar satış gerçekleştirmeye devam etmektedir. Hopper uygulamada kullandığı tahmin algoritmalarını geliştirmek için 6 yıl ve 10 milyon doların üzerinde para harcayarak yatırım yaptı. Daha sonra 2018 yılında da YZ algoritmalarını oluşturmak ve uluslararası pazarlara daha derinlemesine girebilmek için bir 100 milyon dolarlık bir fon daha topladı¹. Hopper 2019 yılının başlarında ise Avupada 2. Dünyada 9. olan en büyük hava yolu şirketlerinden biri olan Almanya merkezli Lufthansa ile YZ alanında yeni bir yatırım anlaşması yaptı². Bu bilgiler bize bu alandaki YZ uygulamalarının hem Ar-Ge hem de ekonomik anlamdaki değerini bir kez daha göstermektedir.

Bu çalışmada uçuş fiyatı tahmininde kullanılan YZ teknolojilerinden makine öğrenmesi algortimaları araştırılmış ve konuyla ilgili yapılan çalışmalar detaylı bir literatür taramasından geçirilerek elde

¹ <https://digital.hbs.edu/platform-digit/submission/hopper-using-ai-to-plan-your-next-vacation/>


² <https://www.phocuswire.com/Lufthansa-Hopper-investment-research>

edilen bulgular ortaya koyulmuştur. Bununla birlikte elde edilen bulgulardan hareketle uçuş fiyatı tahmininde kullanılabilecek potansiyel algoritmalar tespit edilerek bu bölümde bazılarına yer verilmiştir.

2.1. Uçuş Tahmininde Kullanılan Makine Öğrenmesi Algoritmaları

2.1.1. Destek Vektör Makineleri (Support Vector Machine): Kernel-tabanlı popüler bir algoritmadır (Borges, 1998; Vapnik, 1998). Regresyon ve sınıflandırma için kullanılan iki modeli bulunmaktadır. Amaç çizilen aralığa maksimum sayıda örnek girmesini sağlamaktır. Bu çizilen maksimum aralıkların kestiği noktalara destek noktaları denir.

Regresyon amacıyla kullanılan modeline Destek Vektör Regresyonu DVR (Support Vector Regression) adı verilir. Doğrusal DVR var olduğu gibi doğrusal olmayan DVR'de vardır. Doğrusal olmayan DVR modeli uygulanırken Radial Basis Function (RBF) metodu kullanıldığında doğrusal olmayan bir aralık çizebilmek mümkündür.



Şekil 1. (a) Doğrusal ve (b) doğrusal olmayan Destek Vektör Regresyonu (Smola& Scholkopf 2004)

2.1.2. Gradyan Artırım Algoritması (Gradient Boosting): Bu algoritma, makine öğrenmesinde tahminleri bağımsız yapmak yerine sırayla yapan bir çeşit topluluk algoritmasıdır. Amaç zayıf tahminleri iterasyonlarla kademeli olarak güçlü tahminlere dönüştürmektir.

Gradient Boosting'de ilk iterasyonda tahminleri üreten bir y_i^p fonksiyonu oluşturulur. Tahminler ile hedef değer arasındaki fark hesaplanır ve bu farklar için de bir "Loss" fonksiyonunu oluşturulur. İkinci iterasyonda y_i^p ve "Loss" fonksiyonları birleştirilir ve tekrar tahminler ile hedefler arasındaki fark hesaplanır. Böylece sürekli üstüne ekleyerek y_i^p fonksiyonunun başarısı artırılmaya ve tahminler ile hedefler arasındaki fark sıfıra indirilmeye çalışılır.

$$Loss = MSE = \sum (y_i - y_i^p)^2$$


Burada y_i i. hedef değer, y_i^p ise i. tahmin değeri, $L(y_i, y_i^p)$ kayıp fonksiyonu ve α ise öğrenme oranıdır. Tahminleri, kayıp fonksiyonu minimum olacak şekilde elde etmek gereklidir. Gradyan iniş kullanarak tahminler öğrenme oranına göre iterasyonlarda güncellenir ve kayıp fonksiyonunun minimum değerleri bulunur.

$$y_i^p = y_i^p + \alpha * \delta \sum \frac{(y_i - y_i^p)^2}{\delta y_i^p}$$

$$y_i^p = y_i^p - \alpha * 2 * \sum (y_i - y_i^p)$$

Böylece artıkların toplamı sıfıra yakın olması yani tahmin edilen değerler gerçek değerlere olabildiğince yaklaşması arzu edilen durumdur.

2.1.3. Rastsal Orman Algoritması (RF-Random Forest) : Bu algoritma karar ağaçlarına dayanır bir çeşit topluluk öğrenme yöntemidir. Makine öğrenmesinde karar ağaçları (Decision Trees), tahmin modelleri oluşturan denetimli öğrenme tekniğidir. Birden fazla karar ağacı ile karar ormanı oluşturur. Algoritma hem sınıflandırma hem de regresyon problemlerinin çözümünde kullanılmaktadır. Regresyon problemlerinde veri setini daha küçük veri setlerine ayırarak birçok karar ağacı oluşturur. Regresyon probleminde verilen bir girdinin çıktısı bu karar ağaçlarının verdiği çıktıların ortalamasıdır. Çıktı değişkeni kategorik ise RF algoritmasında sınıflandırma, değişken nicel ise RF algoritmasında regresyon problemini çözülür.



Şekil 2. Rastsal Orman Algoritması

2.1.4. K-En Yakın Komşuluk Algoritması (K- Nearest Neighbor) : KNN hem regresyon hem de sınıflandırmada kullanılan denetimli bir öğrenme algoritmasıdır. En yakın komşuları tespit eder ve bu noktaları temel alarak tahminde bulunur. Her iki durumda da, girdi, özellik alanında “k” en yakın eğitim örneklerinden oluşur. Bu algoritmanın sınıflandırma veya regresyon için kullanılıp kullanılmayacağı çıktı değerine bağlıdır.

KNN sınıflandırmasında çıktı, sınıf üyesidir. Bir nesne, komşularının çoğunluk oyunu olarak sınıflanır. KNN regresyonda ise çıktı, örneğin özellik değeridir. Bu değer, en yakın komşularının değerlerinin ortalamasıdır. K-NN parametrik olmayan “lazy” tembel bir öğrenme algoritmasıdır ve eğitim aşaması yoktur. Eğitim verilerini öğrenmez, onun yerine eğitim veri kümesini “ezberler”. Bir tahmin yapmak istenirse tüm veri setinde en yakın komşuları arar.

“k” noktaya en yakın kaç noktanın hesaba katılacağını gösterir.

$$Y = (x_1 + x_2 + \dots + x_k)/k$$

En yakın komşuları belirlemek için aşağıda verilen birkaç mesafe fonksiyonu kullanılabilir.

$$\text{Öklid fonksiyonu } \sqrt{\sum_{i=1}^k (x_i - y_i)^2}$$

$$\text{Manhattan fonksiyonu } \sum_{i=1}^k |x_i - y_i|$$

$$\text{Minkowski fonksiyonu } (\sum_{i=1}^k (|x_i - y_i|^q))^{\frac{1}{q}}$$

3. BULGULAR ve TARTIŞMA

Dünyada bu alanda geliştirilen YZ destekli uygulamalar milyon dolarlık kazanç ve anlaşmaların odağını oluşturmaktadır. YZ ile uçuş fiyatı tahmini konusunda yapılan çalışmaların büyük bir kısmı şirketlerin ticari kaygıları nedeniyle yayınlanmamaktadır. Buna rağmen tüm dünyada bu konu üzerine yapılan makine öğrenmesi çalışmalarına ulaşılmaya çalışılmıştır. Ulaşılan bilimsel çalışmalar analiz edilerek elde edilen bulgular tablo halinde (Tablo 1) bir araya getirilmiştir.

Tablo 1. Makine Öğrenmesi Yöntemleri ile Uçuş Fiyatı Tahmin Çalışmaları

Çalışmalar	Veri Seti	Özellikler	Uygulama Performansı
Rajankar ve Sakharkar (2019) <u>Problem:</u> Minumum fiyat tahmini	Hindistan'da farklı seyahat sitelerinden 3 aylık süre boyunca tek bir rota için toplanmış uçuş bilgileri	Kalkış noktası, varış noktası, kalkış tarihi, kalkış zamanı, varış zamanı, fiyat, havayolu, bilet alış tarihi	Doğruluk değeri Random Forest: 67% MLP: 65% Gradient Boosting: 47% Decision Tree: 45% KNN: 38% SVM: 19%
	Yöntem: Random Forest, MLP, Gradient Boosting, Decision Tree, KNN, SVM		
Vu ve diğerleri (2018) <u>Problem:</u> Bilet fiyatı tahmini	3 ulusal hava yoluna ait haftanın 7 günü için aktarmasız yapılan 51000 uçuş verisi	Havayolu, uçuş numarası, satın alma tarihi, kalkış tarihi, kalkış zamanı, varış zamanı, ücret sınıfı, aktarma sayısı, fiyat, kalkış havalimanı, varış havalimanı, varış tarihi	Doğruluk değeri Stacked Predict Model: 44% Random Forest&MLP: 77%
	Yöntem: Stacked Prediction Model (KNN, Random Forest, Bayesian) Random Forest ve MLP		
Tziridis ve diğerleri (2017) <u>Problem:</u> Bilet fiyatı tahmini	Tek uluslararası rota için yapılmıştır. Thessaloniki-Stuttgart arası 814 uçuştan oluşan veri seti	Kalkış zamanı, varış zamanı, bedava bagaj sayısı, kalkışa kalan gün sayısı, aktarma sayısı, tatil günü (Evet/hayır), gece uçuşu (Evet/hayır), haftanın günü	Doğruluk değeri MLP : 80.28% GRNN : 66.83% ELM: 68.68% RFR: 85.91% RT: 84.13% BRT: 87.42% RSVM-Polynomial: 77.00% RSVM-Linear: 49.40% LR: 57.25%
	Yöntem: Multilayer Perceptron (MLP), Generalized Regression Neural Network (GRNN), Extreme Learning Machine (ELM), Random Forest Regression (RFR), Regression Tree (RT), Bagging Regression Tree (BRT), Regression SVM (RSVM) (Polynomial and Linear) and Linear Regression (LR)		
Liu ve diğerleri (2017) <u>Problem:</u> Minumum fiyat tahmini	19 farklı rotadan oluşan 92 günlük uçuş verileri	Geçmiş bilet fiyatları, kalkış tarihi tatil günü mü (Evet/Hayır), kalkıştan önceli gün sayısı	MAPE (Ortalama Mutlak Hata Yüzdesi) değeri Topluluk Algoritması: 7%.
	Yöntem: Topluluk öğrenme algoritması (KNN, Random Forest ve Bayesian)		
Chen ve diğerleri (2015) <u>Problem:</u> Minumum fiyat tahmini	5 farklı uluslararası rotanın 110 günlük verisi	Rotanın günlük fiyatı, rotanın hedef günden önceki son fiyatları, rotanın haftanın aynı gününe ait fiyatları, rotanın ayın aynı gününe ait fiyatları	MAPE değerleri Learn++.NSE: 10.7% KNN: 12.58% PA: 15.41%
	Yöntem: Topluluk tabanlı öğrenme algoritması (Learn++.NSE), Passive Aggressive Algorithm (PA), KNN		
Lantseva ve diğerleri (2015) <u>Problem:</u> Kilometre bazlı fiyat tahmini	75 ve 90 günlük ulusal-uluslararası uçuş bilgileri AviaSales.com Sabre.com	Kalkış noktası, varış noktası, bilet satın alma tarihi, kalkış tarih, fiyat ve bilet seçenekleri	Yapılmamış
	Yöntem: Regresyon		
Janssen (2014) <u>Problem:</u> Minimum fiyat tahmini	6 farklı hava yolu şirketine ait iki havalimanı arasındaki 60 günlük 2271 uçuş verisi- infare .com	Fiyat, kalkış tarihi, gözlem tarihi, uçuşa kalan gün sayısı, haftanın günü (hafta içi/hafta sonu)	Kalkış tarihinden çok uzak olan günler için iyi tahmin üretir.
	Yöntem: Linear Quantile Mixed regression modeli		

Tablo 1’de bir araya getirilen çalışmalar dikkatle incelendiğinde çalışmaların özellikle belirli rotalar üzerinde kalkış tarihi verilen uçuşların fiyatlarını tahmin etmeye yönelik oldukları görülecektir.

Kullanılan veri setleri belirli bir zaman periyodu boyunca (örn. 6 ay veya 1 yıl gibi) çevrimiçi seyahat acentalarının sayfalarından çekilerek oluşturulmuştur. Çalışmalarda farklı özellikler seçilmekle birlikte genel olarak kalkış noktası, varış noktası, bilet satın alma tarihi, kalkış tarihi, fiyat özellikleri

ortak olarak kullanılmıştır. Ayrıca kullanılan makine öğrenmesi yöntemleri açısından değerlendirildiğinde topluluk algoritmaları, regresyon ve karar ağacı tabanlı algoritmaların ağırlıklı olarak kullanıldığı dikkati çekmektedir. Oluşturulan modellerin performansları incelendiğinde topluluk algoritmaları ile oluşturulan modellerin daha iyi sonuçlar verdiği görülmüştür.

4. SONUÇ

Bu çalışma kapsamında, uçuş fiyatı tahmini konusundaki makine öğrenmesi uygulamaları detaylı olarak incelenmiştir. Bu sayede yeni bir tahmin uygulaması geliştirmek için kullanılması gereken veri boyutu nedir, özellikler nasıl seçilmeli, yüksek performans verecek potansiyel makine öğrenmesi algoritmaları nelerdir ve bu algoritmalar nasıl kullanılabilir gibi önemli soruların cevabı bulunmaya çalışılmıştır. Bununla birlikte, bu çalışmadan elde edilen bilgi ve tecrübeler ile ENUYGUN.COM Ar-Ge Merkezi tarafından yürütülmekte olan “Flight Prices Predictor” projesi kapsamında uçuş fiyatlarını başarılı bir şekilde tahmin edebilecek yeni modeller geliştirilebilmiştir.

YZ teknolojilerinin içinde pek çok farklı makine öğrenmesi algoritması yer almaktadır. Daha önce farklı problemlerin çözümünde ayrı ayrı kullanılan makine öğrenmesi algoritmalarını bugün topluluk öğrenme algoritmaları adı altında birden fazlasının bir arada kullanıldığını görmekteyiz.

Nasıl doğadaki çeşitlilik daha büyük ve karmaşık biyolojik sistemlere katkı sağlıyorsa, makine öğrenmesi modellerinin oluşturduğu topluluklar da birden fazla alt modelin güçlü yönlerini (ve zayıf yönlerini telafi ederek) birleştirerek daha güçlü sonuçlar üretir. Sinir ağları ve birçok makine öğrenmesi algoritmasının modellenmesinden önce eksik değerlerin açık bir şekilde ele alınması ve belirli metotlarla manuel olarak işlenmesi gerekmektedir. Ancak gradyan destekli ağaçlar bunları otomatik bir biçimde işler. Farklı yöntemleri birleştirmek (örneğin, puanların ortalamasını alarak veya harmanlayarak), tahimleri iyileştirmeyi mümkün kılar. Daha net ifade etmek gerekirse makine öğrenmesi modellerinin oluşturduğu topluluklar, tek bir hata kaynağının etkisini azaltarak, farklı tahmin edicileri farklı hata modelleriyle birleştirerek bias ve varyans değerlerini azaltır.

KAYNAKLAR

- Burges, C.J.C. (1998). A tutorial on support vector machines for pattern recognition, *Data Mining Knowledge Discovery*, 2(2), 121- 167.
- Chen, Y., Cao, J., Feng, S. & Tan, Y. (2015). An ensemble learning based approach for building airfare forecast service. In: 2015 IEEE International Conference on Big Data (Big Data), Santa Clara, CA, 2015, 964-969.
- Janssen, T. (2014). A linear quantile mixed regression model for prediction of airline ticket prices. Radboud University.
- Lantseva, A., Mukhina, K., Nikishova, A., Ivanov, S., & Knyazkov, K. (2015). Data-driven Modeling of Airlines Pricing. *Procedia Comput. Sci.* 66, 267–276. ISSN 1877-0509.
- Liu, J., Liu, B., Liu, Y., Chen, H., Feng, L., Xiong, H., & Huang, Y. (2017). Personalized Air Travel Prediction. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 9, 1 - 26.
- Rajankar, S. & Sakharkar, N. (2019). A Survey on Flight Pricing Prediction using Machine Learning, *International Journal Of Engineering Research & Technology (Ijert)* 8(6), 1281-1284.
- Smola, A.J.& Scholkopf, B. (2004). A tutorial on support vector regression. *Stat Comput*; 14(3):199–222. <http://dx.doi.org/10.1023/B:STCO.0000035301.49549.88>.
- Tziridis, K., Kalampokas, T., Papakostas, G.A. & Diamantaras, K.I. (2017). Airfare prices prediction using machine learning techniques, 25th European Signal Processing Conference (EUSIPCO). Kos 2017, 1036–1039.



Vapnik, V.N. (1998). Statistical learning theory. New York: Wiley.

Vu, V.H., Minh, Q.T. & Phung, P.H. (2018). An airfare prediction model for developing markets. In: 2018 International Conference on Information Networking (ICOIN), Chiang Mai, 765–770.