

# Alüminyum Folyo Kalınlığının Destek Vektör Makineleri ile Kısa Dönemli Tahmini

## Short Term Prediction of Aluminium Strip Thickness via Support Vector Machines

Ali ÖZTÜRK

KTO Karatay Üniversitesi, Bilgisayar  
Mühendisliği Bölümü, KONYA  
Havelsan A.Ş., ANKARA  
[aliozturk2002@gmail.com](mailto:aliozturk2002@gmail.com)

Rıfat ŞEHERLİ

Panda Alüminyum A.Ş., ANKARA  
[rifat@pandaalm.com](mailto:rifat@pandaalm.com)

**Özetçe**—Soğuk haddeleme sürecinin temel prensibi, haddeleme makinesindeki açıcı ve sarıcı motorların ürettiği gerilmedir. Eğer gerilme uygun şekilde düzenlenmezse, folyo kalınlığı yüzey üzerinde homojen olmayacaktır ve hatta kopmalar meydana gelebilecektir. Bu yüzden, alüminyum folyo kalınlığının kısa süreli tahmini, gerilmenin kontrolü için çok önemlidir. Bu çalışmada, doğrusal olmayan zaman dizisi analizi yöntemleri kaydedilen kalınlık verilerine uygulanarak, en uygun zaman gecikmesi ve gömülme boyutuna sahip gömülme vektörleri elde edilmiştir. Farklı tahmin ufukları için, gömülme vektörleri giriş ve kalınlık değeri çıkış olmak üzere elde edilen veri kümesi ile Destek Vektör Makinelerinin (DVM) tahmin performansı 10-katlı çapraz geçerlilik yöntemi ile tayin edilmiştir. Karşılaştırma sonuçları, değişik üs değerleri ile Polynomial çekirdek, Radial Basis Function (RBF) çekirdeği, ve Evrensel Pearson VII fonksiyon (PUK) çekirdek için verilmiştir. PUK çekirdekli DVM en doğru sonuçları vermiştir. Buna en yakın doğruluk oranları  $p=3$  üs değeri ile oluşturulan Polynomial çekirdekli DVM olmuştur. Fakat model oluşturma zamanı PUK-DVM'ye göre çok daha uzundur. RBF çekirdekli DVM en kısa sürede model oluşturmuş fakat en kötü sonuçları vermiştir.

**Anahtar Kelimeler** — Zaman Dizileri; Kısa Süreli Tahmin; Destek Vektör Makineleri; Kaos Teorisi

**Abstract** — The fundamental principle of cold rolling process is the tension produced by the coiling and uncoiling motors of the rolling machine. If the tension is not properly regulated, the strip thickness will not be homogenous over the surface and even ruptures may occur. Therefore, short-term prediction of the aluminium strip thickness is important to control the tension. In this study, nonlinear time series analysis methods were applied to the recorded thickness data in order to obtain the embedding vectors with appropriate embedding dimension and time delay. For various prediction horizons, the embedding vector and corresponding thickness value pairs were used as the data set to assess the prediction performance of Support Vector Machines (SVM) with k-fold cross validation. The comparison results were given for Polynomial kernel with different exponent

values, RBF kernel and Universal Pearson VII function (PUK) kernel. The SVM model with PUK kernel gave the most accurate results. The closest accuracy levels to PUK were belonging to Polynomial kernel of exponent  $p=3$ , but the time taken to build the SVM model with Polynomial kernel was very longer than the SVM model with PUK. The RBF kernel had the shortest SVM model building time with the worst accuracy levels.

**Keywords** — Time Series; Short-Term Prediction; Support Vector Machines; Chaos Theory

### 1. GİRİŞ

Alüminyum folyo yüzeyinin tamamında istenen kalınlığın korunması için gerilme değeri ve bunun düzenlenmesi çok önemlidir [1]. Açıcı ve sarıcı motorların açılma hızı, folyoya uygulanan gerilmenin miktarını belirler. Alüminyum makarasının yarıçapına bağlı olarak, motorların açılma hızı değişmelidir. Bu değer motorlara uygulanan armatür ve alan akımları ile belirlenir. Mevcut PLC sistemi, soğuk haddeleme makinesinin sadece çıkışında bir adet kalınlık ölçüm cihazı yer almaktadır. Bu cihazın saniyede bir ölçtüğü kalınlık değeri, alüminyum folyoya uygulanacak gerilmeyi belirlemektedir. Merdanelerin içinden bir saniyede 5 metrelik alüminyum levha akmaktadır. Bu bir saniyelik düzenleme mantığı, bahsedilen gecikmeye bağlı olarak kalınlık hassasiyetini etkilemektedir. Bu yüzden, merdanelerin açılma hızlarının daha etkin biçimde düzenlenmesi için kısa süreli tahmin gereklidir.

Literatürde, ölçülen zaman dizisi verilerinin kısa dönemli tahmini için kaos teorisi yöntemlerinin kullanıldığı pek çok çalışma bulunmaktadır [2][3][4] [5][6][7][8].

Bu çalışmada, alüminyum folyo kalınlığının en fazla 10 saniye ilerisi için tahmini araştırılmıştır. Kalınlık zaman dizisi verilerinden elde edilen gömülü zaman gecikmesi vektörleri, değişik çekirdek fonksiyonları (PUK, Polynomial çekirdek ve RBF çekirdek) içeren DVM modelleri üretmek

için kullanılmıştır. Farklı tahmin ufukları için DVM modellerinin tahmin doğruluğu performansları karşılaştırılmıştır.

## 2. DOĞRUSAL OLMAYAN ZAMAN DİZİSİ ANALİZİ

Kaos teorisine göre eğer gözlemlenen bir zaman dizisi kaotik davranış gösteriyorsa, alt yatan dinamik süreç belli bir deterministik kurala dayanır. Bu durumda, gözlemlenen veri üzerinde deterministik nedenselliğin kaybolduğu noktaya kadar kısa dönemli tahmin yapmak mümkündür [9]. Buradaki temel fikir, gözlemlenen tek boyutlu zaman dizisi verisine karşılık gelen kaotik çekicinin yörüngelerini elde etmek üzere, zaman dizisini n-boyutlu gömülme uzayında yeniden oluşturmaktır.

### 2.1. Zaman dizisi verisinin yeniden oluşturulması

Takens gömülme teoremine göre [10], eğer çekicinin gerçek boyutu  $D_A$  ise, yörüngelerin kesişimi gömülme boyutunun  $D_E > 2D_A$  şeklinde seçilmesiyle önlenir. Gömülen zaman gecikmesi vektörleri, orijinal zaman dizisine topolojik olarak eşdeğerdir. Tahmin sistemine t anında girecek veriler,  $D_E$  boyutlu vektör uzayında  $Y(n)$  vektörleri şeklindedir. Bu vektörler,  $x(t)$  gözlemlenen zaman verisi üzerinde aynı  $\tau$  zaman gecikmesi aralıklarında  $D_E$  adet gözlemlenen veri içerir [11].

$$Y(n) = (x(n), x(n+\tau), \dots, x(n+(D_E-1)\tau)) \quad (1)$$

Gömülme vektörlerinin zaman içinde değişimi  $Y(n) \rightarrow Y(n+1)$  şeklinde gösterilebilir. Çekicinin doğru biçimde inşa edilmesi için, zaman gecikmesi ( $\tau$ ) and en küçük gömülme boyutunun ( $D_E$ ) hesaplanması çok önemlidir.

Bu çalışmada, zaman gecikmesinin bulunması için [12]'de önerilen karşılıklı bilgi yöntemi kullanılmıştır. S karşılıklı bilgi değeri farklı  $\tau$  değerleri için aşağıdaki gibi hesaplanmıştır.

$$S = -\sum_{ij} p_{ij}(\tau) \ln \frac{p_{ij}(\tau)}{p_i p_j} \quad (2)$$

Burada,  $p_i$  bir gözlem değerinin i. aralıkta bulma olasılığı,  $p_j$  bir gözlem değerinin j. aralıkta bulma olasılığı ve  $p_i p_j$  bir gözlem değerini i. aralıkta ve  $\tau$  zaman sonraki gözlem değerini j. aralıkta bulmak için birleşik olasılıktır. S değerinin minimum olduğu ilk  $\tau$  değeri optimum zaman gecikmesini verir.

En küçük gömülme boyutunu bulmak için [13]'te önerilen yöntem kullanılmıştır. Bu yöntem, zaman dizisindeki gürültüye bağlı olarak yanlış sonuçları önlemek için [14]'te önerilen Sözde Yakın Komşular (SYK) algoritmasına küçük değişiklikler içermektedir. Zaman dizisinin standart sapması  $\sigma$ , sözde yakın komşular için eşik değeri  $r$  ve faz uzayındaki vektörler arasındaki uzaklık en büyük farka göre bulunmak üzere, SYK istatistiği aşağıdaki gibi hesaplanmaktadır.

$$X_{SYK}(r) = \frac{\sum_{n=1}^{N-m-1} \Theta \left( \frac{|S_n^{(m+1)} - S_{k(n)}^{(m+1)}|}{|S_n^{(m)} - S_{k(n)}^{(m)}|} - r \right) \Theta \left( \frac{\sigma}{r} - |S_n^{(m)} - S_{k(n)}^{(m)}| \right)}{\sum_{n=1}^{N-m-1} \Theta \left( \frac{\sigma}{r} - |S_n^{(m)} - S_{k(n)}^{(m)}| \right)} \quad (3)$$

Burada,  $S_{k(n)}^{(m)}$ ,  $S_n$  vektörünün en yakın komşusu ve  $k(n)$ , n'den farklı olan ve  $|S_n - S_{k(n)}|$  değerini minimum yapan zaman dizisi indisidir. Paydaki, ikinci Heaviside fonksiyonu, başlangıç uzaklıkları  $\sigma/r$ 'dan büyük olan vektörleri elimine etmek için kullanılmaktadır. Bu fonksiyon payda da aynı nedenden dolayı bulunmaktadır.  $X_{SYK}(r)$  değerinin sıfır olduğu  $r$  değeri kaotik çekicinin minimum gömülme boyutu olarak kabul edilir.

## 3. KISA DÖNEMLİ TAHMİN

Karmaşık ve düzensiz sinyallerin geleneksel doğrusal olmayan analiz yöntemleri ile modellenmesi zordur. Bunun nedeni, çok sayıda parametrenin yer alması ve karakteristiklerinin karmaşıklığıdır. Bu yüzden, sinir ağları [15] [16] [4], RBF ağları [17], pekiştirme öğrenmesi [11], bulanık mantık [16] gibi makine öğrenmesi ve yumuşak hesaplama algoritmaları etkin doğrusal olmayan tahmin yöntemleri olarak ele alınmıştır. DVM performansı [8]'de, polinom ve oransal yakınsama, yerel polinom teknikleri, RBF ve yapay sinir ağları ile karşılaştırılmıştır. Mackey-Glass zaman dizisi, Lorenz zaman dizisi ve Ikeda haritası gibi kaotik zaman dizileri üzerinde DVM'nin performansı diğer yöntemlerden daha iyi bulunmuştur.

Bu çalışmada, PUK çekirdeği, farklı üs değerleri ile Polynomial çekirdek ve RBF çekirdek kullanan DVM'lerin 10-adım ileri tahmin performansları incelenmiştir.

### 3.2. Destek Vektör Makineleri

Destek Vektör Makineleri (DVM) istatistiksel öğrenme teorisine dayanmaktadır [18] ve temel fikir, doğrusal olmayan haritalama fonksiyonu yardımıyla X giriş veri kümesini daha yüksek boyutlu F özellik uzayına çevirerek, bu yeni uzayda bir optimal hiper düzlem oluşturmaktır [19]. Regresyon için DVM kullanıldığında, hiper düzlem mümkün oldukça fazla sayıda noktaya yakın olacak şekilde oluşturulur.

Destek Vektör Regresyonun (DVR) genel biçiminde [20], [21], kestirim fonksiyonu

$$f(x) = (w \times \phi(x)) + b \quad (4)$$

Burada,  $w$  ve  $b$  verilerden hesaplanacak katsayılardır.  $\phi(x)$ , özellik uzayında doğrusal olmayan bir fonksiyondur.

Minimize edilecek risk fonksiyonu

$$R(w, \xi^*) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N (\xi_i + \xi_i^*) \quad (5)$$

ve,

$$d_i - w\phi(x_i) - b_i \leq \epsilon + \xi_i \quad (6)$$

$$(w\phi(x)) + b - d_i \leq \epsilon + \xi_i^* \quad (7)$$

Burada,  $\xi_i, \xi_i^* > 0$ .

DVR kestirim fonksiyonu

$$f(x) = \sum_{i=1}^{NSV} (\alpha_i - \alpha_i^*) K(X, X_i) + b \quad (8)$$

Burada,  $\alpha_i$  ve  $\alpha_i^*$  değerleri, tahminleri d hedef değerine ilerlemeye zorlayan Lagrange katsayıları ve NSV destek vektörlerinin sayısıdır.

$K(X_i, X_j) = \phi(X_i)\phi(X_j)$  çekirdek fonksiyonu Mercer teoremini[22] sağlayan herhangi bir fonksiyon olabilir ve giriş uzayını doğrusal olmayan ilişkilerin doğrusal olarak gösterilebildiği yüksek boyutlu özellik uzayına dönüştürür. Çekirdek fonksiyonun seçimi verinin, genellikle bilinmeyen, doğasına bağlıdır. Bu yüzden, en iyi giriş-çıkış eşleme fonksiyonu, en yüksek genelleme performansını verecek şekilde değişik çekirdek fonksiyonları uygulanarak ve en iyi parametreleri bularak deneme yoluyla belirlenebilir. Bu çalışmada, kalınlık zaman dizisi üzerinde tahmin performanslarını belirlemek üzere, Pearson VII fonksiyonu tabanlı çekirdek (PUK) fonksiyonu [23], Polynomial çekirdek fonksiyonu  $[1 + (XX_i)]^p$  ve RBF çekirdek fonksiyonu  $\exp(\frac{1}{2\sigma^2} \|X - X_i\|^2)$  ile karşılaştırılmıştır.

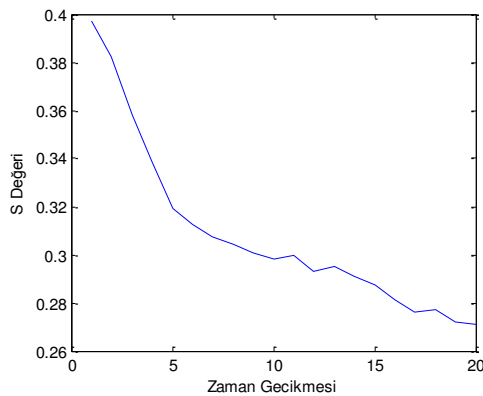
Sıralı Minimal Optimizasyon (SMO) algoritması [21] için, [24]'te bazı etkinlik iyileştirmeleri önerilmiştir. Dual problem için Karush-Kuhn-Tucker (KKT) koşulları ile ilişkili en uygunluk kriterlerindeki ip uçları kullanılarak, tek eşik değeri yerine iki eşik parametresinin kullanımı önerilmiştir.

C,  $\epsilon$  ve çekirdek parametreleri p ve  $\sigma^2$  kullanıcı tarafından belirlenir. Karmaşıklık parametresi C, yakınsama fonksiyonunun düzgünlüğünü kontrol etmek için kullanılır ve  $\epsilon$  yuvarlama hatasının tolere edildiği sınırı belirler [25].

DVM modellerinin gerçekleştirilmesinde, Weka yazılım paketinin 3.7 versiyonu [26] kullanılmıştır.

#### 4. DENEYSEL SONUÇLAR VE TARTIŞMA

Şekil 1'de kalınlık zaman dizisi için  $\tau$  zaman gecikmesi değerinin nasıl bulunduğu gösterilmiştir. S değerinin ilk minimum olduğu  $\tau$  değeri en uygun zaman gecikmesi olarak seçilir. Burada, S değerinin ilk minimum olduğu  $\tau$  değeri 10 olarak bulunmuştur.

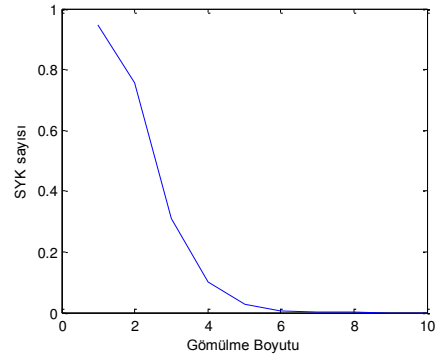


Şekil 1. Kalınlık zaman dizisi için zaman gecikmesi ( $\tau$ ) değerinin bulunması


Şekil 2'de, [13]'te gerçekleştirilen SYK yöntemine göre  $D_E$  gömülme boyutunun nasıl bulunduğu gösterilmiştir. SYK sayısının sıfır olduğu gömülme boyutu, minimum gömülme boyutu olarak seçilir. Kalınlık zaman dizisinin faz uzayında yeniden oluşturulması için gerekli  $D_E$  değerinin 9 olduğu görülmektedir.  $D_E$  değeri, 0'dan büyük tüm Theiler penceresi [13] değerleri için 9 olarak bulunmuştur.

Polynomial çekirdek fonksiyonu, RBF çekirdek fonksiyonundan daha doğru sonuçlar vermiştir. Öte yandan, polynomial çekirdek fonksiyonundaki p üs değerleri doğruluğu etkilemektedir. Üs değeri arttıkça doğruluk artmaktadır, fakat DVM modelinin oluşma süresi uzamaktadır. Geçerli değer olan  $p=1$  değerinden farklı olarak, daha küçük p üs değerleri (0.7, 0.5, 0.3) ve daha büyük p üs değerleri (5, 10), C karmaşıklık parametresi olarak uygulanmıştır. Fakat, doğruluk değerlerinde bir iyileşme olmamıştır. Benzer şekilde,  $\epsilon$  için 0.001'dan farklı olarak 0.01, 0.1 ve 1 değerleri verilmiştir. Yüksek  $\epsilon$  değerleri DVM modelinin doğruluğunu azaltmıştır.

Tüm çekirdek fonksiyonları Şekil 3'te karşılaştırılmıştır. Şekil 3'te görüldüğü gibi, PUK çekirdekli DVM modeli en iyi doğru tahmin performansı sergilemiştir. Üs değeri p=3 olan Polynomial çekirdek fonksiyonlu DVM ikinci en iyi performansa sahiptir. En kötü performans RBF çekirdekli DVM'ye aittir.



Şekil 2. Kalınlık zaman dizisi için en küçük gömülme boyutunun ( $D_E$ ) bulunması



Şekil 3. Değişik çekirdek fonksiyonlu DVM'lerin karşılaştırılması

DVM modellerinin tahmin performansını karşılaştırmak için kullanılan Ortalama Mutlak Hata (OMH) ve Kök Ortalama Kare Hata (KOKH) fonksiyonları aşağıda verilmiştir. Bu fonksiyonlarda  $O_j$  çıkış değeri ve  $T_j$  hedef değerdir. Hesaplama işlemi  $n$  adet değer için yapılmaktadır.

$$OMH = \frac{1}{n} \sum_{j=1}^n |O_j - T_j| \quad (9)$$

$$KOKH = \sqrt{\frac{1}{n} \sum_{j=1}^n (O_j - T_j)^2} \quad (10)$$

Değişik çekirdek fonksiyonları için DVM modellerinin oluşturulması için geçen ortalama süreler Tablo 1’de verilmiştir.

DVM Modeli	RBF	Poly (p=1)	Poly (p=2)	Poly (p=3)	PUK
Ortalama Süre (sn)	94.62	196.1	273.3	1033	394

Tablo 1. DVM Modellerinin oluşturulması için geçen ortalama süreler

Sonuçlar, 2.5 GHz Intel Core i5 işlemci ve 6 GB belleğe sahip bir dizüstü bilgisayar ile elde edilmiştir.

## KAYNAKÇA

[1] Filatov, A.S., “İki Yönlü Soğuk Hadde Tezgâhlarının Elektro Tahrik Sistemleri Tezgâhların Otomatikleştirilmesi. Çeviri: Musa Özalp”, Etibank Alüminyum A.Ş. Eğitim Müdürlüğü Tercüme Yayınları, 1986.

[2] Dangelmayr G., Gadaleta S., Hundley D., Kirby M., “Time series prediction by estimating Markov probabilities through topology preserving maps”, Proc. SPIE 3812, Applications and Science of Neural Networks, Fuzzy Systems, and Evolutionary Computation II, 86, 1999.

[3] Iokibe T., Fujimoto Y., “Predicting Combustion Pressure of Automobile Engine Employing Chaos Theory”, Proceedings of 2001 IEEE Int. Symp. On Comp Intell. In Robotics and Automation.511-516, 2001.

[4] Plagianakos V.P., Tzanaki E., “Chaotic Analysis of Seismic Time Series and Short Term Forecasting Using Neural Networks”. IEEE Int. Joint Conf. on Neural Networks. 3: 1598-1602, 2001.

[5] Yang H., Duan X., “Chaotic Characteristics of Electricity Price and Its Forecasting Model”, Canadian Conf. On Electrical and Computer Eng. 1: 659-662, 2003.

[6] Michanos S.P., Tsakoumis A.C., Fessas P., Vladov S.S., Mladenov V.M., “Short-term Load Forecasting Using a Chaotic Time Series”, International Symposium on Signals, Circuits and Systems, 2003.

[7] Wang H., Chen G., Lee J., “Complex Dynamical Behaviours of Daily Data Series in Stock Exchange. Physics Letters”. A 333:246-255, 2004.

[8] Mukherjee S., Osuna E., Giroso F., “Nonlinear Prediction of Chaotic Time Series Using Support Vector Machines”, IEEE Workshop on Neural Networks for Signal Processing, 1997.

[9] Iokibe T., Koyama M., Taniguchi M., “Industrial Applications of Short-term Prediction on Chaotic Time

Series by Local Fuzzy Reconstruction Method”, 1st International Conference on Knowledge-Based Intelligent Electronic Systems, 1997.

[10] Takens, F., “Detecting Strange Attractors in Turbulence”. Lecture Notes in Math. 898: 226-381, Springer, New York, 1981.

[11] Kuremoto, T., Obayashi, M., Yamamoto, A., Kobayashi, K., “Predicting Chaotic Time Series by Reinforcement Learning”, Proc. of The 2nd Intern. Conf. on Computational Intelligence, Robotics and Autonomous Systems, 2003.

[12] Fraser, A. M., Swinney, H. L., “Independent coordinates for strange attractors from mutual information”, Physics Rev. A 33. 22: 1134-1140, 1986.

[13] Hegger R., Kantz H., Schreiber T., “Practical implementation of nonlinear time series methods: The TISEAN package”, CHAOS. 9: 413, 1999.

[14] Kennel M. B., Brown R., Abarbanel H. D. I., “Determining embedding dimension for phase-space reconstruction using a geometrical construction”, Physics Rev. A. 45: 340-353, 1992.

[15] Oliveira, K. A., Vannucci A., da Silva E. C., “Using artificial neural networks to forecast chaotic time series”, Physica A, No.284, pp.393-404, 1996.

[16] Kodogiannis V., Lolis A., “Forecasting Financial Time Series using Neural Network and Fuzzy System-based Techniques”, Neural Computing & Applications, No.11, pp.90-102, 2002.

[17] Casdagli M., “Nonlinear prediction of chaotic time series”, Physica D: Nonlinear Phenomena Vol. 35, Issue 3, pp.335-356, 1989.

[18] Mohandes M.A., Halawani T.O., “Support vector machines for wind speed prediction”, Renewable Energy, 29, pp.939-947, 2004.

[19] Osowski S., Garanty K., “Forecasting of daily meteorological pollution using wavelets and support vector machine”, Engineering Applications of Artificial Intelligence, 20, pp.745-755, 2007.

[20] Collobert R., Benegio S., “SVM Torch: Support Vector Machines for Large-Scale Regression Problems”, Journal of Machine Learning Research, 1, pp.143- 160, 2001.

[21] Smola A.J, Scholkopf B., “A Tutorial on support vector regression”, Neuro COLT Technical Report NC-TR-98-030, Royal Holloway College, University of London, UK, 1998.

[22] Min J.H., Lee Y., “Bankruptcy prediction using support vector machine with optimal choice of kernel function parameters”, Expert Systems with Applications, 28, pp.603-614, 2005.

[23] Ustun B., Melssen W.J., Buydens L.M.C., “Facilitating the application of Support Vector Regression by using a universal Pearson VII function based kernel”, Chemometrics and Intelligent Laboratory Systems, 81: 29-20, 2006.

[24] Shevade S.K., Keerthi S.S., Bhattacharyya C., Murthy K.R.K., “Improvements to the SMO Algorithm for SVM Regression”, IEEE Transactions on Neural Networks. Vol. 11, No. 5, 1188-1193, 2000.

[25] Radhika Y., Shashi M., “Atmospheric Temperature Prediction using Support Vector Machines”, International Journal of Computer Theory and Engineering, Vol. 1, No.1, 1793-8201, 2009.

[26] Hall M., Frank E., Holmes G., Pfahringer B., Reutemann P., Witten I.H., “The WEKA Data Mining Software: An Update”, SIGKDD Explorations, Volume 11, Issue 1, 2009.