

# MLR 및 SVR 기반 선형과 비선형회귀분석의 비교 - 풍속 예측 보정

## Comparison of MLR and SVR Based Linear and Nonlinear Regressions - Compensation for Wind Speed Prediction

김 준 봉\* · 오 승 철\*\* · 서 기 성\*  
(Junbong Kim · Seungchul Oh · Kisung Seo)

**Abstract** - Wind speed is heavily fluctuated and quite local than other weather elements. It is difficult to improve the accuracy of prediction only in a numerical prediction model. An MOS (Model Output Statistics) technique is used to correct the systematic errors of the model using a statistical data analysis. The Most of previous MOS has used a linear regression model for weather prediction, but it is hard to manage an irregular nature of prediction of wind speed. In order to solve the problem, a nonlinear regression method using SVR (Support Vector Regression) is introduced for a development of MOS for wind speed prediction. Experiments are performed for KLAPS (Korea Local Analysis and Prediction System) re-analysis data from 2007 to 2013 year for Jeju Island and Busan area in South Korea. The MLR and SVR based linear and nonlinear methods are compared to each other for prediction accuracy of wind speed. Also, the comparison experiments are executed for the variation in the number of UM elements.

**Key Words** : Wind Speed Prediction, Unified Model, Model Output Statistics, Linear Regression, Non-Linear Regression, Support Vector Regression, UM Elements

### 1. 서 론

회귀분석은 주어진 데이터 집합으로부터 독립변수와 종속변수 사이의 상관관계를 나타내는 관계식을 구하고, 현재 데이터 집합에 존재하지 않는 새로운 값을 추정하거나 예측하는 데 사용된다. 회귀분석에서 선형과 비선형의 비교는 흥미로운 문제이다. 대부분의 회귀분석에서 선형회귀분석법이 사용되고 있으며, 대상 모델이나 시스템의 특성에 상관없이 이러한 경향은 두드러진다. 주요 이유는 다음과 같다. 1) 시스템에 부분적으로는 비선형성이 존재하더라도, 전체적으로는 선형에 가까운 특성을 가진다. 2) 다중 변수의 개수가 많아질 경우, 이들의 선형 결합은 어느 정도 비선형 효과를 포함할 수 있다. 3) 비선형 특성을 가진 시스템을 정확히 표현할 수 있는 비선형회귀분석법을 발견하기 어렵다. 일반적인 비선형회귀 분석은 최고 차수나 회귀식의 구조가 고정되어 있으며, 이러한 제한된 범위 내에서 계수 추정을 통해 오차를 최소화한다.

더불어, 대부분의 회귀분석 문제에서 독립변수의 개수가 5개

이하 또는 많아야 10개 내외인 경우가 일반적이며, 대량의 개수를 가진 (예로 50~60개) 회귀분석 문제는 잘 다루어지지 않고 있다. 이러한 경우에 대해서 선형과 비선형 회귀분석의 비교는 실용적 측면에서 매우 유용하다. 독립변수의 개수가 많아지게 되면 높은 상관관계로 인한 다중공선성의 문제가 발생할 수 있지만, 독립변수의 개수를 줄이는 것은 모델의 최적화에 대한 한계를 수반한다.

이전 연구에서[2] 진화적 기호회귀 분석기법인 유전 프로그래밍을 사용하여 풍속 예보에 대한 비선형 보정 수식을 생성하는 기법을 제안하고, 강풍 발생에 대한 예측 실험을 남한 전지역의 600개 AWS(Automatic Weather System) 지점에 대해서 수행하였으며, UM 모델의 결과와 비교했다. 또한, 풍속 예측용 보정 수식 생성에 관한 또 다른 연구에서 다중선형회귀분석법, Ridge[3] 및 Lasso[4] 회귀분석법과 유전 프로그래밍 기반의 비선형 접근법의 성능을 비교한 바 있다[5].

본 논문에서는 이전의 유전 프로그래밍을 이용한 비선형 보정식 접근 대신에 커널 함수를 통해 차원을 높여서 비선형으로 특징 벡터들을 분리하는 SVM(Support Vector Machine)[6] 기반의 SVR(Support Vector Regression)[7] 접근법을 적용한다. 이것은 SVR을 적용한 초기 연구[8]를 확장한 것이다. 유전 프로그래밍 기반 기법은 주어진 독립변수 중에서 일부를 선택하여 다양한 비선형 함수를 결합시키는 데 비해서, SVR은 모든 독립변수를 사용하면서 단일 커널 변환을 통한 비선형 회귀분석을 수행하

† Corresponding Author : Dept. of Electronics Engineering,  
Seokyeong University, Korea.  
E-mail : ksseo@skuniv.ac.kr

\* Electronics Engineering, Seokyeong University, Korea.

\*\* Omron Korea, Korea.

Received : February 7, 2016 ; Accepted : March 17, 2016

는 차이가 있다.

서울, 부산, 제주지역에 대해서 2007년~2013년의 UM과 KLAPS 데이터를 대상으로 SVR의 선형과 비선형 커널함수를 사용하여 풍속 예측의 보정 실험을 수행하고, MLR 기반의 선형 MOS 방식과 비교한다.

## 2. MOS(Model Output Statistics)와 UM 인자

MOS(Model Output Statistics)[9]는 수치예보모델의 오차를 줄이는 예보기술로서, 수치예보모델의 계통오차를 설명할 뿐만 아니라, 기상 인자들과 모델 변수들 사이의 통계적 관계를 결정한다. 즉, 식 (1)과 같이 기존 모델에 의한 예측값에 보정값을 합하여 최종 예측값을 구하는 방식이다.

현재 기상청의 단기 풍속 예보는 영국에서 개발된 통합모델인 UM(Unified Model)예보 모델의 예측값에 선형회귀분석 기반의 MOS(Model of Statistics)에 의한 보정값을 합하는 방법을 사용하고 있다[10].

기존의 MOS에서 사용되는 예보 보정 기법은 식 (2)와 같이 잠재적 예보인자들과 계수의 결합을 통한 선형적인 수식으로 구성되어 있다. 여기서  $\Delta WSS$ 는 풍속에 대한 보정량이며,  $VAR_i$ 는 표 1에 나와 있는 UM의 64개 예보인자를 가리킨다. 그리고  $\alpha_i$ 는 각 예보인자의 계수이다.

$$WSS_{Pred} = WSS_{UM} + \Delta WSS \tag{1}$$

$$\Delta WSS = \alpha_1 TS + \alpha_2 T8 + \dots + \alpha_N VAR_N + \alpha_{N+1} \tag{2}$$

표 1 UM 인자

Table 1 Elements of UM

Group	Code
Air Temperature	TS, T8, T7, T5
Thickness	DZ18, DZ17, DZ85
Dew-Point Depression	TDD10, TDD8, TDD7, TDD5
Specific Humidity	QS, Q10, Q8, Q7, Q5
Q Difference	DQS5, DQ85, DQ75
Relative Humidity	RHS, RH8, RH7, RH5
Mean RH	MRH17, MRH15, MRH85
Vapour Pressure Deficit	VPDS, VPD10, VPD8, VPD7, VPD5
Zonal Wind	US, U8, U7, U5
Meridional Wind	VS, V8, V7, V6
Wind Speed	WSS, WS8, WS7, WS5
NW Wind Speed	NWS, NW8, NW7, NW5
NE Wind Speed	NES, NE8, NE7, NE5
SW Wind Speed	SWS, SW8, SW7, SW5
SE Wind Speed	SES, SE8, SE7, SE5
Total Rain Amount	PCPN
Lapse rate	LR87, LR85
K-Index	KI
Severe Weather Threatening Index	SWEATI

## 3. MLR(Multiple Linear Regression)과 SVR(Support Vector Regression)

### 3.1 다중선형회귀분석 (Multiple Linear Regression)

다중선형회귀분석[10]은 복수 개의 독립변수를 가지고 종속변수를 예측하기 위한 선형회귀모델로서, 식 (3)의 형태로  $x$ 는 독립변수,  $\beta$ 는 각 독립변수의 계수,  $\epsilon$ 은 잔차이다.

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n + \epsilon \tag{3}$$

일반 선형회귀분석에서 회귀계수(coefficient)의 추정량을 구하기 위해서는 식 (4)로 표현되는 최소자승법(least squared method)을 사용한다.

$$\min \left( \sum_{i=1}^n \epsilon^2 \right) = \min \left( \sum_{i=1}^n (y_i - \beta_0 - \dots - \beta_i x_i)^2 \right) \tag{4}$$

그러나 독립변수의 개수가 많아지게 되면 변수들 사이의 높은 상관관계로 인해 다중공선성의 문제가 발생할 수 있지만, 독립변수의 개수를 줄이는 것은 모델의 최적화에 대한 한계를 수반한다.

### 3.2 SVR (Support Vector Regression)

SVR(Support Vector Regression)은 학습 데이터의 분류 예측에 사용되는 SVM을  $\epsilon$ -무감도 손실함수를 도입하여, 임의의 실수값을 예측하도록 일반화한 방법이다[7]. SVM은 기계학습의 한 방법으로서, 주어진 데이터가 어떤 분류에 속하는지 분류해내기 위한 알고리즘이다[6].

그림 1에서 각 클래스의 최외각 벡터(support vector)를 지나는 직선을 각각  $w^T x + b = 1$  과  $w^T x + b = -1$  로 표현할 수 있고, 각 클래스의 데이터는 이 직선들 위, 또는 아래에 존재하기 때문에, 식 (5)의 조건을 만족해야 한다.

$$\begin{aligned} w^T x_i + b &\geq 1 && \text{for } x_i \text{ of the first class} \\ w^T x_i + b &\leq -1 && \text{for } x_i \text{ of the second class} \end{aligned} \tag{5}$$

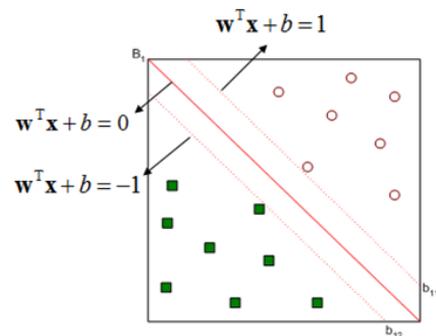


그림 1 SVM 분류기

Fig. 1 SVM classifier

이 때 클래스를 나누는 두 직선 사이의 거리는  $\frac{2}{|w|}$ 가 되고, 클래스간 거리를 최대화 하는 것이 SVM의 목적이기 때문에  $|w|$ 를 최소화 시켜야 한다. 이를 위해 식 (6)과 같은 라그랑지 승수를 이용한다.

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^m \alpha_i (y_i \cdot [w^T x_i + b] - 1) \quad (6)$$

식 (6)에서  $\alpha$ 는 라그랑지 상수이고  $y_i$ 는 입력 데이터 클래스에 대한 값이다.  $y_i$ 에 대한 식은 (7)과 같다.

$$y_i = \begin{cases} 1 & \text{if } x_i = \text{class1} \\ -1 & \text{if } x_i = \text{class2} \end{cases} \quad (7)$$

그림 2에 SVR의 개념도가 나와 있다. SVM과 유사하게 실제 값과 예측 값의 차이를 최대한  $\epsilon$  이내로 유지시키는 것이 목적이다.  $\epsilon$ 는 오차허용률(또는 epsilon width of tube)이라고 하며, 사용자에게 의해 선택된다. 예측 성능을 나타내는 오차는  $f(x) \pm \epsilon$  경계선과의 거리로 계산한다.

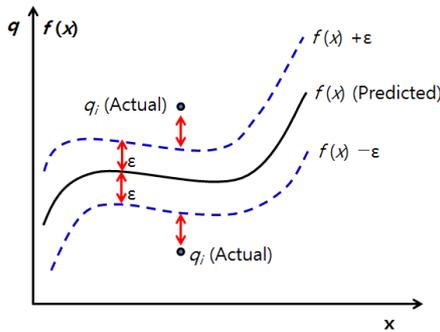


그림 2 SVR 개념도  
Fig. 2 Concept of SVR

SVR의 비선형 확장은 SVM과 마찬가지로 선형적으로 분리가 가능하지 않은 원래의 특징 공간을 더 높은 차원의 새로운 공간으로 변환하여 수행한다. 즉, 커널함수를 사용하여 입력 공간의 저차원 비선형 회귀문제를 사상을 통해 고차원 선형 회귀문제로 변환한다.

#### 4. MLR과 SVR 비교 실험

SVR 기반 풍속 예측 실험은 KLAPS(실황자료)[10] 데이터에 대해서 총 163개 격자점을 대상으로 수행하였으며, 예보구간, 발표시각 그리고 사용된 실험 데이터 년도, 기상인자 개수는 다음과 같다.

- 격자점 수(KLAPS) : 163개 격자점  
(서울 19개, 부산 43개, 제주도 101개)

- 예보 구간 : 21개(+06H ~ +66H, 3H 간격)
- 발표 시각 : 00UTC
- 학습 : 2007년, 2008년, 2009년, 2011년
- 테스트 : 2013년
- 기상인자 : UM 인자 총 64개

실험은 다중선형회귀분석(MLR)으로 보정한 방법과, 커널함수인 linear, polynomial, rbf를 적용한 SVR 기반의 보정 방법들을 각각 비교하였다. 2007, 2008, 2009, 2011년 데이터를 학습에 사용하고, 2013년도 데이터에 대해서 평가하였다. 표 2는 서울, 부산, 제주지역 163개 격자점에 MLR을 이용한 보정 방법과 SVR을 이용한 보정 방법들의 RMSE를 비교한 것이다. MLR을 이용한 보정 방법에 비해 SVR을 이용한 3가지 보정 방법들이 모두 우수함을 확인할 수 있었다.

21개 예보구간(+06H~+66H)에서 선형회귀분석 보정을 적용한 UM+ $\Delta$ MLR의 RMSE는 1.980, UM+ $\Delta$ SVR중 선형인 linear 커널은 1.826으로 약 0.154(7.8%)정도 향상되었다. 비선형인 rbf커널은 RMSE가 1.823으로 linear 커널과 비슷한 성능이었다. 마지막으로 polynomial 커널은 RMSE 1.7960으로 UM+ $\Delta$ MLR보다 약 0.184(9.3%)정도 개선되어서 3가지 커널 함수 중 가장 우수한 성능을 보였다.

프로그램은 SVM-Light[11] 코드를 컴파일하여 사용하였고, 오차허용률  $\epsilon$ 는 0.1, polynomial 커널의 차수 d는 3, rbf 커널의 gamma는 1로 설정하였다.

표 2 각 풍속예보 보정기법의 지역별 RMSE 비교

Table 2 Performance comparison results of MOS based wind prediction for each areas in RMSE

		서울	부산	제주	평균
UM+MLR	training	2.626	1.562	2.119	2.031
	test	3.042	1.562	1.958	1.980
UM+SVR	training (linear)	2.561	1.122	1.917	1.782
	training (PLM)	2.521	1.068	1.835	1.712
	training (RBF)	2.345	1.018	1.744	1.622
	test (linear)	3.211	1.197	1.833	1.826
	test (PLM)	3.187	1.164	1.804	1.796
	test (RBF)	3.103	1.260	1.824	1.823

#### 5. 인자 수 변화에 따른 비교 실험

4절의 실험을 확장하여 UM 인자의 개수를 변화시키면서 각 방법을 다시 비교하였다. 인자수는 3, 5, 10, 16, 24, 32, 64개로 변경하며 실험하였다. 사전 학습에 의한 인자 선택을 통해 얻은 인자 구성은 표 3과 같다.

표 3 선택 인자의 변화

Table 3 Variation of selected UM elements

인자수	선택된 인자
3	WSS, US, VS
5	+ QS, V8
10	+ LR85, Q8, WS7, U8, U5
16	+ WS8, U7, V7, VPDS, RHS, V5
24	+ LR87, Q7, DQ85, KI, SWEATI, RH8, TDD8, MRH17
32	+ RH5, Q5, RH7, TDD7, TDD5, DQ75, VPD1000, VPD850
64	+ TS, T8, T7, T5, DZ18, DZ17, DZ85, TDD10, Q10, DQS5, RMH15, MRH85, VPD700, VPD500, WS5, NWS, NW8, NW7, NW5, NES, NE8, NE7, NE5, SWS, SW8, SW7, SW5, SES, SE8, SE7, SE5, PCPN

그림 3에 서울 지역의 인자수 변화 결과가 나와 있다. 오차 성능은 MLR이 가장 우수하며, SVR RBF, PLM, 그리고 linear 순으로 나온다. MLR은 인자수가 증가함에 따라 오차가 약간 감소함을 보인다. SVR의 경우 linear와 PLM은 오차의 변화가 미미하나, RBF의 경우는 인자가 24개까지 오차가 감소하다가 다시 증가하나 초기 값보다는 감소하였다.

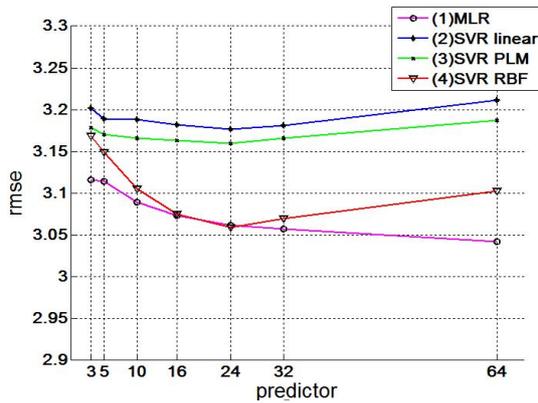


그림 3 인자 개수 변화에 따른 MLR, SVR의 서울지역 RMSE 그래프

Fig. 3 RMSE graphs of MLR and SVRs in Seoul according to variations of weather elements

부산 지역의 인자수 변화 결과는 그림 4에 나와 있다. 오차 성능은 서울과 다르게 SVR PLM이 가장 우수하며, RBF, linear 그리고 MLR 순으로 나온다. 그림 3과 마찬가지로 MLR은 인자수가 증가함에 따라 오차가 상당히 감소함을 보인다. 그러나 SVR의 경우 linear, PLM, RBF 세 커널 모두 인자수가 증가할수록 오차가 지속적으로 상당히 증가하였다.

그림 5에는 제주 지역의 인자수 변화 결과가 나와 있다. 오차 성능은 부산과 유사하나 SVR RBF가 가장 우수하며, PLM, linear 그리고 MLR 순으로 나온다. 서울, 부산과 마찬가지로 MLR은 인자수가 증가함에 따라 오차가 감소함을 보인다. SVR 군의 경우

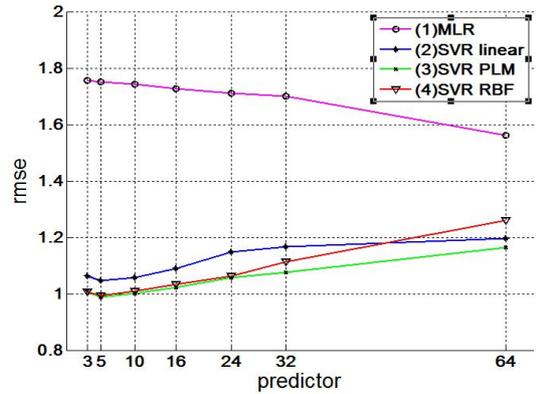


그림 4 인자 개수 변화에 따른 MLR, SVR의 부산지역 RMSE 그래프

Fig. 4 RMSE graphs of MLR and SVRs in Busan according to variations of weather elements

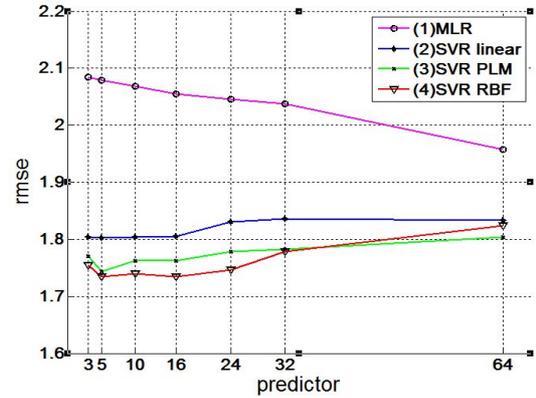


그림 5 인자 개수 변화에 따른 MLR, SVR의 제주도 지역 RMSE 그래프

Fig. 5 RMSE graphs of MLR and SVRs in Jeju Island according to variations of weather elements

부산과 유사하나 linear, PLM, RBF 모두 16 인자까지 정체를 보이며, 그 이후 인수가 증가할수록 오차가 약간 증가하였는데, 부산에 비해서 폭은 크지 않았다.

그림 6은 서울, 부산, 제주도 지역의 인자수 변화 결과의 평균 그래프이다. 각 방법들의 오차 성능의 순서와 인자수 변화에 따른 오차 변화는 그림 5의 제주도 지역과 매우 비슷하다.

표 4는 그림 3-6의 그래프들에 대한 모든 RMSE 수치들을 비교 정리한 것이다. 가장 우측의 64개 인자 결과는 표 2의 결과와 같으며, 수치 비교의 편의를 위하여 중복하여 표시하였다.

전체적으로 선형인 MLR이나 SVR linear에 비선형 방법인 SVR PLM과 RBF가 우수한 성능을 보였다. 다만 같은 선형인 SVR linear는 MLR에 비해서 성능이 우수했고, 같은 SVR 군내의 비선형인 PLM, RBF보다 약간 더 오차가 크게 나왔을 뿐 큰 차이를 보이지 않았다.

표 4 인자개수 변화에 따른 MLR, SVR의 보정실험 결과 (RMSE)

Table 4 Results of MLR and SVRs based compensations for wind speed prediction according to variations of weather elements (RMSE)

	training/test	model	kernel	3	5	10	16	24	32	64
Seoul	training	MLR		2.721	2.717	2.697	2.678	2.660	2.651	2.626
		SVR	linear	2.612	2.586	2.563	2.555	2.561	2.564	2.561
			PLM	2.601	2.58	2.555	2.534	2.544	2.539	2.521
			RBF	2.593	2.566	2.511	2.468	2.44	2.428	2.345
	test	MLR		3.116	3.114	3.089	3.073	3.062	3.057	3.042
		SVR	linear	3.202	3.189	3.188	3.182	3.177	3.181	3.211
			PLM	3.178	3.17	3.166	3.163	3.16	3.166	3.187
			RBF	3.169	3.149	3.105	3.075	3.059	3.07	3.103
Busan	training	MLR		1.748	1.74	1.731	1.71	1.695	1.684	1.562
		SVR	linear	1.162	1.138	1.125	1.135	1.173	1.186	1.222
			PLM	1.108	1.078	1.073	1.079	1.103	1.11	1.068
			RBF	1.101	1.068	1.055	1.044	1.043	1.057	1.018
	test	MLR		1.758	1.754	1.744	1.73	1.714	1.703	1.562
		SVR	linear	1.064	1.047	1.059	1.089	1.148	1.167	1.197
			PLM	1.008	0.989	1.002	1.023	1.059	1.076	1.164
			RBF	1.006	0.994	1.011	1.033	1.064	1.115	1.26
Jeju	training	MLR		2.24	2.233	2.222	2.205	2.186	2.177	2.119
		SVR	linear	1.994	1.968	1.945	1.951	1.981	1.989	1.917
			PLM	1.956	1.883	1.884	1.885	1.901	1.902	1.835
			RBF	1.934	1.861	1.844	1.829	1.816	1.821	1.744
	test	MLR		2.084	2.079	2.068	2.055	2.046	2.037	1.958
		SVR	linear	1.804	1.802	1.804	1.805	1.83	1.836	1.833
			PLM	1.77	1.743	1.762	1.763	1.779	1.783	1.804
			RBF	1.755	1.734	1.739	1.734	1.746	1.778	1.824
All	training	MLR		2.166	2.159	2.148	2.130	2.112	2.102	2.031
		SVR	linear	1.847	1.821	1.801	1.806	1.835	1.844	1.809
			PLM	1.807	1.752	1.748	1.748	1.765	1.767	1.713
			RBF	1.791	1.734	1.714	1.696	1.685	1.690	1.623
	test	MLR		2.118	2.114	2.102	2.088	2.077	2.068	1.980
		SVR	linear	1.772	1.765	1.769	1.777	1.807	1.817	1.826
			PLM	1.733	1.710	1.725	1.731	1.750	1.758	1.796
			RBF	1.722	1.704	1.706	1.705	1.720	1.754	1.824

인자수의 변화에 대한 결과에서는 MLR이 인자수가 증가함에 따라 오차가 감소함을 뚜렷하게 보였으나, SVR linear, PLM, RBF 커널 모두 인자수의 증가에 별 영향을 받지 않거나 오히려 오차가 약간 증가하는 경향을 나타냈다. 독립 변수로 선택되는 기상 인자수가 적을 때는 선형 과 비선형간의 차이가 많이 나고, 인자수가 많아지면 그 차이가 많이 줄어들 것이라고 예상하였고, 실제 세 지역 평균 그래프에서는 이를 뒷받침하는 결과를 얻었으나 지역별 편차가 있어서 더 많은 지역에 대한 실험이 필요하다고 생각된다.

위의 현상들이 나타난 이유들은 다음과 같다. 첫째, 회귀분석을 통해 모델을 구성하고 이를 통해 풍속을 예측하는 접근이 아니고, UM 모델에서 예측한 결과에 상기 선형 및 비선형 회귀분석을 통해서 보정하는 MOS 방식이기 때문에 풍속 예측에 대한 RMSE 오차와 인자들 간의 관계가 약간의 간접적인 관계를 가지고 있기 때문일 수 있다.

둘째, 사전 학습에서 얻어진 상위 선택 인자들이 WSS, US, VS, QS, V8등 대부분 풍속에 직접적으로 관련된 인자이기 때문에, 인자수에 큰 영향을 받지 않은 것으로 보인다.

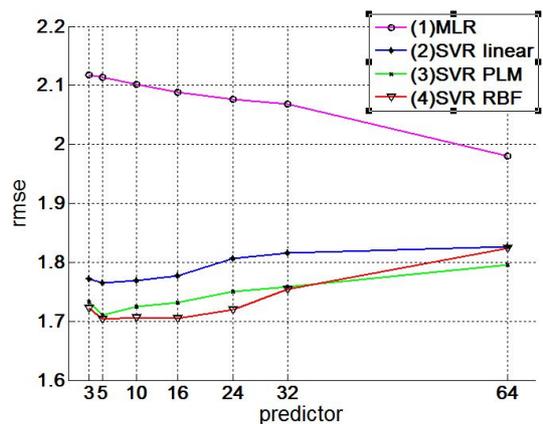


그림 6 인자 개수 변화에 따른 MLR, SVR의 서울, 부산, 제주도 지역 RMSE 그래프

Fig. 6 Average RMSE graphs of MLR and SVRs in all area according to variations of weather elements

## 6. 결론 및 향후 연구

본 논문에서는 풍속 예측을 위하여 SVR 기반의 선형, 비선형 보정기법을 수행하고 선형회귀분석 기반의 보정 기법과 비교하였다. KLAPS 데이터에 대한 서울, 부산, 제주지역 163개 격자점을 대상으로 UM의 64개 인자를 모두 사용한 실험한 결과에서, MLR 기반의 보정 기법의 경우 RMSE가 약 1.980인 반면, SVR 기반의 비선형(polynomial 커널) 보정기법은 1.796으로 약 0.184 (9.3%)정도 향상되었다. 전체적으로 선형에 비해서 비선형 방법인 SVR PLM과 RBF이 우수한 성능을 보였다. 또한, 선형 방법 중에서 SVR linear가 MLR에 비해서 성능이 우수했고, 같은 SVR 군내의 비선형인 PLM, RBF과도 성능이 약간 더 떨어질 뿐 큰 차이를 보이지 않았다.

인자수의 변화 실험에서는 MLR이 인자수 증가에 따라 오차가 감소함을 뚜렷하게 보였으나, SVR linear, PLM, RBF 세 커널은 모두 인자수의 증가에 별 영향을 받지 않거나 오히려 오차가 약간 증가하는 경향을 나타냈다.

향후, 더 많은 지역에 대한 확장 실험을 통해, 결과의 신뢰성을 높이는 것과, 같은 선형 접근법인 MLR과 SVR linear의 차이가 상당히 나는 현상에 대한 분석이 필요하다.

## References

- [1] S. Weisberg, Applied Linear Regression, 3rd Edition, Wiley, New York, USA, 2003
- [2] B. Hyeon, K. Seo, Y. Lee, "Evolutionary Nonlinear Regression Based Compensation Technique for Short-range Prediction of Wind Speed using Automatic Weather Station", The Transactions of the Korean Institute of Electrical Engineers, vol. 64, No.1, pp. 107-112, 2015
- [3] J. Yi, "A Study on an Estimation of Probable Flood Flow using Ridge Regression", Journal of Korean Society of Civil Engineers, vol. 20, No.1-B, pp.35-43, 2000
- [4] C. Park, "Simple Principal component analysis using Lasso", Journal of the Korean data & Information Science Society, vol.24, No.3, pp.533-541, 2013
- [5] D. Kim, and K. Seo, "Comparison of Linear and Nonlinear Regressions and Elements Analysis for Wind Speed Prediction", Journal of Korean Institute of Intelligent Systems, Vol. 25, No. 5, pp. 477-482, 2015
- [6] V. Vapnik, Statistical Learning Theory, Wiley, New York, USA, 1998
- [7] V. Vapnik, Three remarks on the support vector method of function estimation, Advances in kernel methods, pp. 25-41, MIT Press, Cambridge, MA, USA, 1999
- [8] J. Kim, S. Oh, K. Seo, "Comparison of SVR Based Linear and Nonlinear Regressions for Multiple Elements Model", Proceedings of KIIS Autumn Conference 2015 Vol. 25, No. 2., pp. 69-70, 2015. 10.

- [9] H. R. Glahn, D. A. Lowry, "The use of model output statistics (MOS) in objective weather forecasting", J. Appl. Meteor., 11, pp. 1203 - 1211, 1972
- [10] Korea Meteorological Administration, <http://www.kma.go.kr>.
- [11] T. Joachims, SVM-light, [svmlight.joachims.org](http://svmlight.joachims.org)

## 저 자 소 개



### 김 준 봉 (Junbong Kim)

2013년~현재 서경대학교 전자공학과 재학 (학사). 관심분야는 진화연산, 기상예측



### 오 승 철 (Seungchul Oh)

2014년 서경대학교 전자공학과 졸업(학사). 2016년 서경대학교 대학원 전자컴퓨터공학과 졸업(석사). 한국오므론전장 기술연구소 연구원, 관심분야는 진화연산, 기상예측, 영상인식.



### 서 기 성 (Kisung Seo)

1993년 연세대학교 대학원 전기공학과 졸업 (박사). 1999~2003년 Michigan State University, Genetic Algorithms Research and Applications Group, Research Associate, 2002~2003년 Michigan State University, Electrical & Computer Engineering, Visiting Assistant Professor, 2011~2012년 Michigan State University, BEACON(Bio / computational Evolution in Action Consortium) Center, Visiting Scholar, 1993년~현재 서경대학교 전자공학과 교수. 관심분야는 진화연산, 기상예측, 지능로봇.