

SVM방법을 이용한 풍력발전기 고장 예측 및 발전수익 평가

(Fault prediction of wind turbine and Generation benefit evaluation
by using the SVM method)

신준현* · 이윤성 · 김성열 · 김진오**

(Jun-Hyun Shin · Yun-Seong Lee · Sung-Yul Kim · Jin-O Kim)

Abstract

Wind power is one of the fastest growing renewable energy sources. The blades length and tower height of wind turbine have been growing steadily in the last 10 years in order to increase the output amount of wind power energy. The amount of wind turbine energy is increased by increasing the capacity of wind turbine, but the costs of preventive, corrective and replacement maintenance are also increased accordingly. Recently, Condition Monitoring System that can repair the fault diagnose and repair of wind turbine in the real-time. However, these system have a problem that cannot predict and diagnose of the fault. In this paper, wind turbine predict methodology is proposed by using the SVM method. In the case study, correlation analysis between wind turbine fault and external environmental factors is performed by using the SVM method.

Key Words : Support Vector Machine, Maintenance, Wind Turbine, Prediction

1. 서 론

풍력발전은 신재생 에너지원 중 전력생산단가가 싸고 에너지원을 자연에서 쉽게 얻을 수 있으며 에너지원이 영구적이고, 폐기물이 없으며 탄소배출이 없는

청정에너지이기 때문에 전 세계적으로 빠르게 성장하고 있다. 현재 풍력발전은 좀 더 경제적인 에너지를 생산하기 위하여 풍력발전기 출력을 향상시키고 있는데, 풍력발전기 출력은 터빈의 지름의 제곱에 비례하고 풍속의 세제곱에 비례하게 된다. 풍력발전기는 높은 출력을 얻기 위하여 지상에서 좀 더 높은 위치에 풍력발전기를 설치하기 위하여 타워의 높이를 높이고 (고도가 높은 지역이 평균 풍속이 강하기 때문에), 지름의 길이를 길게 하기 위하여 블레이드의 길이를 증가시키고 있다. 하지만 풍력발전기의 출력을 높이기 위한 위의 사항들이 풍력발전기 예방, 고장 유지보수 비용 및 컴포넌트 교체비용을 증가하게 되는 단점을 발생하게 되었다.

* 주저자 : 한양대학교 전기공학과
** 교신저자 : 한양대학교 전기공학과
* Main author : Department of Electrical Engineering, Hanyang University
** Corresponding author : Department of Electrical Engineering, Hanyang University
Tel : 02-2220-0347, Fax : 02-2220-1856
E-mail : jokim@hanyang.ac.kr
접수일자 : 2014년 2월 12일
1차심사 : 2014년 3월 6일, 2차심사 : 2014년 3월 7일
심사완료 : 2014년 3월 11일

풍력발전 유지보수를 위해서 기존에는 정기적인 수리를 시행하는 시간기준유지보수(Time Based Maintenance, TBM)를 많이 적용하였는데, 고장을 즉시 감지하지 못하는 단점과 불필요한 유지보수를 많이 하게 되는 이유로 최근에는 상태감시시스템(Condition Monitoring System, CMS)을 기반으로 한 상태기준유지보수(Condition Based Maintenance, CBM)를 많이 시행하고 있다. 이러한 상태기준유지보수는 고장을 즉시에 탐지 및 수리할 수 있어 기존의 불필요한 유지보수를 줄이고 고장을 즉시에 탐지하여 수리하는 장점을 가지게 되었다. 이러한 상태감시시스템은 고장을 미리 탐지하고 예측하여 진단하는 것이 중요하다.

본 논문에서 제안하는 방법은 고장을 고장이전에 예측하여 풍력발전기 가용률을 증가시키게 되는데 이러한 가용률의 증가는 풍력발전기 운영시간을 증가시킴으로써 풍력발전기 발전수익을 증가시킬 수 있다.

2. 본 론

2.1 Support Vector Machine(SVM)

패턴인식은 다 그룹 및 두 그룹을 나누는 방법으로 식별기준에 따라 각 그룹을 식별하는 인지과학 및 인공지능 분야에 속하는 방법론으로써, 최근 인지과학에서 많이 사용되고 있다.

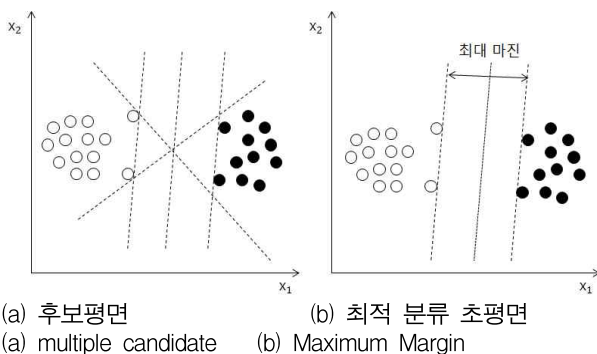


그림 1. 최적 분류 초평면
Fig. 1. Optimal Separating Hyperplane




그림 2. 일반적인 판별분석방법과 SVM방법의 예시
Fig. 2. Discriminant analysis Method

Support Vector Machine은 다양한 패턴인식 방법 중 우수한 해결능력을 보여주는 판별법으로써 두 그룹을 식별하는 식별방법이다.

SVM은 두 그룹을 분리할 수 있는 수많은 후보평면들 가운데(그림 1의 왼쪽에 있는 점선) 마진이 최대가 되는 (maximum margin) 식별 면(hyperplane)(그림 1의 오른쪽에 있는 실선)을 찾는 방법이다. 이러한 SVM방법은 최근 일반적인 판별분석방법과 비교되고 있는데, 이러한 비교분석을 그림 2에 나타내었다.

그림 2의 (a)는 일반적인 판별분석방법으로 흰색 그룹과 검은색 그룹의 데이터가 주어졌을 경우, 두 그룹의 중심을 구한 후 그 가운데의 최적의 초평면(Hyperplane)을 구함으로써 흰색과 검은색 그룹을 나누는 방법이다. 하지만 오른쪽의 SVM 방법에서는 각 그룹의 중심이 아닌 두 그룹 사이의 경계에 있는 데이터에 초점을 맞추어 선을 그은 다음 그 가운데에 새로운 선을 그어 최적의 초평면을 정하게 된다. 이렇게 함으로써 새롭게 등장한 흰색 데이터는 왼쪽의 일반적인 방법에 의해서는 검은색으로 잘못 분류되지만 SVM방법에서는 흰색으로 올바르게 예측된다는 것을 알 수 있다[1].

이렇게 SVM방법은 최적의 초평면을 각 데이터의 중심을 통해서 구하는 것이 아닌 경계를 통해 찾음으로써 흰색그룹과 검은색그룹을 구분하는 오차가 최소가 된다. SVM방법을 이용하여 경계를 나눌 시에 나누는 경계면을 수식 (1)과 같이 나타낼 수 있다.

$$F = W^T X + b, W \in R^n \quad (1)$$

여기서 X 는 각 축을 의미하고, W 는 X 의 방향을 나타내는 벡터이고, b 는 축의 절편을 의미하고, R 은 실수집합을 의미하게 된다.

(1)번 수식은 두 그룹의 마진이 최대가 되는 평면을 나타내게 된다. 최적의 초평면에서 각 그룹간의 거리는 $1/\|W\|$ 로 나타낼 수 있는데, 두 그룹의 에러율을 최소화 하기 위해서는 (마진을 최대화하기 위해서는) $2/\|W\|$ 를 최대화 시키는 것과 같다. 위의 설명을 수식 (2)와 같은 목적함수로 표현할 수 있게 되는데,

$$\min \frac{1}{2} W^T W \tag{2}$$

제약조건, $y_i (W^T X + b) \geq 1, i = 1, 2, \dots, n$

여기서 y 는 클래스를 나타낸다.

(2)번 수식을 라그랑지 함수로 표현하면 (3)번 수식이 된다.

$$L(W, b, \alpha) = \frac{1}{2} \|W\|^2 - \sum_{i=1}^n \alpha_i [y_i (W^T X + b) - 1] \tag{3}$$

(3)번 수식을 최대화하기 위하여 (4)번 수식을 유도할 수 있으며, (4)번 수식을 풀게 되면 최적 분류 초평면을 구할 수 있게 된다[1-2].

$$\max L(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j x_i^T x_j \tag{4}$$

제약조건, $\sum_{i=1}^n \alpha_i y_i = 0, \alpha_i \geq 0$

또한 SVM에서는 kernel 함수를 사용하여 저차원에서 발생한 문제를 고차원의 공간으로 사상(mapping)을 실시하게 되는데, 이러한 사상은 비선형문제를 효율적으로 푸는데 많은 도움이 된다. 사상은 데이터들이 실제로 존재하는 입력 공간(input space, 저차원의 공간)에서는 잘 나누어지지 않는 문제를 feature space라는 고차원의 공간으로 이동시켜서 판별문제를 풀게 된다. 사상에 대한 예시를 그림 3에 나타내고 있다[1].

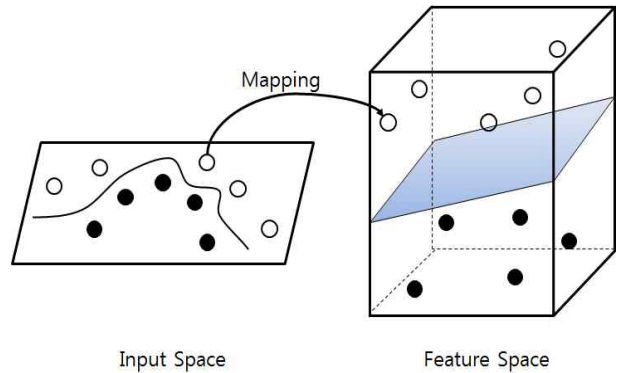


그림 3. SVM 사상의 예시
Fig. 3. Examples of the SVM mapping

2.2 제안하는 방법의 이론적 배경

2.2.1 외부환경요인이 풍력발전기 고장에 미치는 영향

풍력발전기는 일발전인 발전기보다 낮은 가용률을 가지는데, 일반적인 발전기는 출력원이 안정되어 있는 반면 신재생에너지원은 발전원이 안정되어 있지 않아 전력변환장치 및 발전기에 Stress가 많이 가해져 고장이 일반적인 발전기보다는 많이 발생하게 된다. 이렇듯 신재생에너지원은 외부환경요인과 밀접한 관련이 있는 에너지원으로써, 날씨에 따른 외부환경요인과 고장과의 상관관계분석을 패턴인식 기법을 사용하여 분석하여 고장의 원인을 찾아 낼 수 있다.

2.2.2 고장예측으로 인한 가용률 변화

풍력발전기 운영자들은 고장을 즉시 탐지 및 수리하기 위하여 상태감시시스템을 도입하여 가용률을 극대화 시키는 결과를 가져오고 있다. 하지만 이러한 상태감시시스템은 고장을 즉시 탐지만 가능할 뿐 고장이 일어나기 이전에 고장을 미리 예측 및 대비가 불가능하다는 단점이 존재한다.

고장을 미리 예측하고 대비하게 되면 기존의 상태감시 시스템을 이용한 방법보다 MTTR(Mean Time To Repair, 고장이후부터 다시 동작하기까지의 시간)이 짧아지기 때문에 가용률이 증가하게 된다. 기존의 상태감시 시스템을 이용한 방법을 수식 (5)로, SVM방법을 이용하여 고장을 예측하고 미리 대비하여 MTTR

이 줄어든 수식을 (6)로 나타낼 수 있으며, 이것을 그림 4로 표현하였다.

$$A_{wt} = \frac{MTTF}{MTTF + MTTR} \quad (5)$$

$$A_{wt,SVM} = \frac{MTTF}{MTTF + (MTTR - \Delta t)} \quad (6)$$

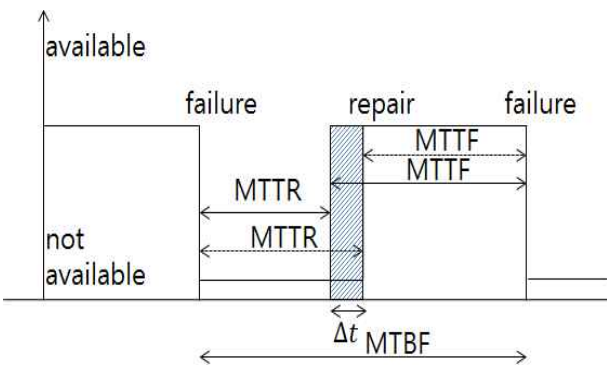


그림 4. SVM방법으로 인한 MTTR감소
Fig. 4. MTTR reduction by using the SVM method

2.2.3 고장 예측으로 인한 발전수익 증가

풍력발전기 고장 예측이 가능해짐에 따라 풍력발전기 고장을 미리 예측할 수 있으며, 이러한 예측은 풍력발전기 발전수익을 증가시키는 결과를 가져오게 된다. 풍력발전기 고장 예측을 하지 않은 방법의 발전수익은 수식 (7), 예측함으로써 발전수익이 증가하게 되는 것을 수식 (8)과 같이 나타낼 수 있다.

$$C_{gn} = C.F. \cdot Cap_{wind} \cdot C_{wind, cost} \cdot A_{wt} \cdot t_{total} \quad (7)$$

$$C_{\Delta gn} = Pr_{SVM} \cdot C.F. \cdot Cap_{wind} \cdot C_{wind, cost} \cdot A_{wt, SVM} \cdot t_{total} \quad (8)$$

여기서 $C.F.$ 는 Capacity Factor로써 풍력발전기 전체 용량 대비 실제 생산한 전력량의 비를 나타내는 지수이며, Cap_{wind} 는 풍력발전기 용량을 의미하며, $C_{wind, cost}$ 는 MWh당 풍력에너지 가격을 의미한다. 또한 A_{wt} 은 기존방법의 가용률이고, $A_{wt, SVM}$ 은 예측한 방법의 가용률이고, t_{total} 은 전체 운영시간을 의미한다. Pr_{SVM} 은 예측 확률을 의미하고, $A \cdot t_{total}$ 은 풍력발전기 실제 운영시간을 나타냄을 알 수 있다.

2.2.4 제안하는 방법의 Flowchart

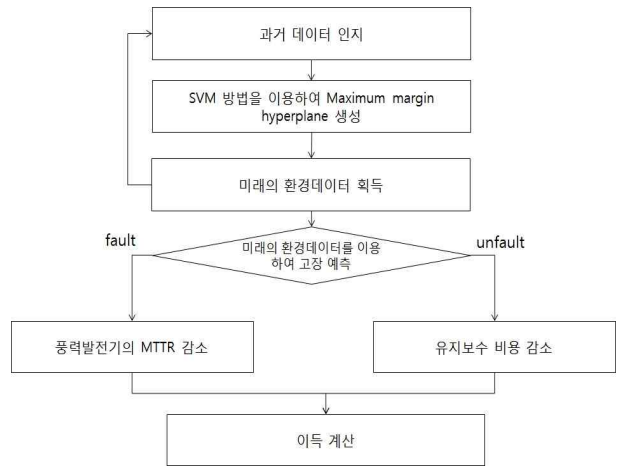


그림 5. 제안하는 방법의 Flowchart
Fig. 5. Flowchart by using the proposed method

제안하는 방법은 과거 환경데이터를 인지하고 SVM방법을 이용하여 최대 마진을 가지는 초평면을 생성하며 미래의 환경데이터를 취득할 시에, 이 데이터를 바탕으로 고장 예측을 실시하게 된다. 이 경우 고장이 일어난다고 예측되면 미리 대비하여 풍력발전기의 MTTR을 감소시켜 가용률을 증가시키고, 고장이 일어나지 않게 된다면 유지보수를 하지 않아 유지보수 비용을 절감할 수 있다.

2.3 사례연구

풍력발전기의 외부 환경요인들이 많이 존재하게 되는데, 이러한 외부환경요인 중에서 풍력발전기 고장에 가장 많은 영향을 미치는 요인 중 온도와 풍속 2가지를 선택하여, 이 2가지 외부환경요인과 풍력발전기 고장과의 상관관계를 도식화하면 그림 6과 같다.

풍력발전기의 외부환경데이터는 2012년 9월부터 2013년 8월까지의 1년치 데이터를 사용하여 분석하였다. 초록색 별은 고장이 발생하지 않은 날을 의미하고, 빨간색 동그라미는 고장이 발생한 날을 의미하게 된다. 기온이 높고 풍속이 낮을 경우 고장이 발생하지 않는 것을 볼 수 있으며, 풍속과 상관없이 기온이 낮을 경우 고장이 많이 발생하는 것을 볼 수 있다.

이렇듯 외부환경요인과 풍력발전기 고장과의 상관 관계를 그림 6과 같이 나타내 볼 수 있다.




그림 6. 온도, 풍속과 고장과의 상관관계
Fig. 6. Correlation analysis between failure and 2 weather conditions




그림 7. RBF함수를 이용한 Hyperplane(커널의 폭=1)
Fig. 7. SVM analysis by using the RBF function(width of kernel is 1)

외부환경요인과 고장과의 상관관계를 커널함수 중 우수한 해결능력을 보여주는 RBF를 이용하여 분석을 실시하게 되는데, 이러한 RBF함수는 커널의 폭을 지정할 수 있게 된다. 그림 7, 8, 9, 10, 11, 12는 RBF함수의 커널의 폭을 1부터 0.01까지 변화시키면서 최적 분

류 초평면을 그린 것이다. 이러한 최적분류 초평면은 커널함수의 폭 말고도 3가지의 최적화 문제를 푸는 방법(SMO, QP, LS)을 이용하여 분석을 실시할 수 있게 되는데, 각 방법을 그림에 표시하였다[3-4].

여기서 SMO는 앞에서 설명한 수식 (1)-(4)를 이용하여 최적의 초평면을 구한 것이고, QP와 LS는 quadratic programming과 Least square method를 이용하여 푸는 것이다.

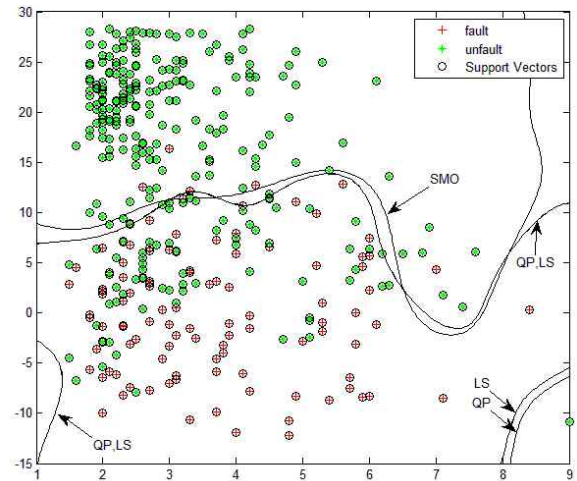


그림 8. RBF함수를 이용한 Hyperplane(커널의 폭=0.5)
Fig. 8. SVM analysis by using the RBF function(width of kernel is 0.5)

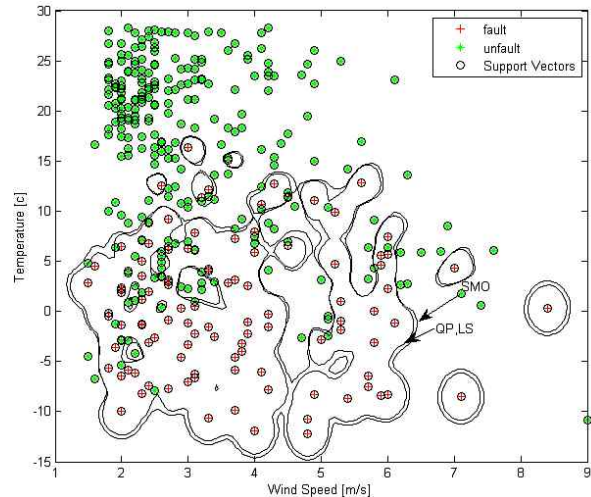


그림 9. RBF함수를 이용한 Hyperplane(커널의 폭=0.1)
Fig. 9. SVM analysis by using the RBF function(width of kernel is 0.1)

커널의 폭이 감소하면서 예측율(인지율)이 좋아지는 것을 볼 수 있지만 이러한 예측율은 커널의 폭을 너무 작게 하면 고장인 데이터를 인지하지 못하여 예측율이 나빠지는 것을 볼 수 있다.




그림 10. RBF함수를 이용한 Hyperplane (커널의 폭 0.05)

Fig. 10. SVM analysis by using the RBF function (width of kernel is 0.05)

써 두 그룹의 마진이 최대가 되는 곡선을 정할 수 있다. 이러한 최적분류 초평면 곡선은 Linear(직선), Quadratic(2차), polynomial(다차), RBF(Gaussian Rasial Basis Function), MLP(Multilayer Perceptron Kernel)등이 존재한다[5-6].




그림 12. RBF함수를 이용한 Hyperplane (커널의 폭=0.01)

Fig. 12. SVM analysis by using the RBF function (width of kernel is 0.01)




그림 11. RBF함수를 이용한 Hyperplane (커널의 폭=0.02)

Fig. 11. SVM analysis by using the RBF function (width of kernel is 0.02)

각 커널함수와 최적화 기법을 사용하여 예측율을 구하면 표 1을 얻을 수 있는데, SVM방법을 이용함으로써

Linear, Quadratic, Polynomial, MLP는 커널의 폭이 존재하지 않아 커널의 폭을 설정할 수 없으며, MLP는 QP로 풀 수 없는 것을 표 1을 보고 알 수 있다. 이 경우 내일의 날씨가 예측되면, 예측된 날씨 데이터를 가지고 풍력발전기 고장 발생 유무에 대한 관별을 통하여 풍력발전기 고장을 미리 대비할 수 있게 되는데, 이러한 대비는 비용감소로 이어지게 된다.

풍력발전기 고장 예측을 SVM방법을 이용하여 실시함으로써 MTTR이 감축하는 양에 따라 가용률이 증가하게 된다. 수식 (7), (8)을 이용하여 발전 수익을 구할 수 있으며, 이렇게 구한 발전수익을 표 2에 MTTR이 감축하는 양을 10% 단위로 하여 나타내었다.

여기서 풍력발전기 용량은 5MW, MWh당 가격은 18만원이고, C.F.는 0.2이고, Pr_{SVM}은 80%라고 가정하였다. 운영시간이 길어지게 되면 발전수익이 더 증

가하게 되는 것을 알 수 있으며, 발전기가 늘어나게 되면 발전수익 및 이득은 더 증가하게 되는 것을 알 수 있다.

표 1. 각 커널함수와 최적화 기법을 사용하여 구한 예측율

Table 1. Prediction values by changing the kernel functions and methods

Kernel functions	커널의 폭	SMO	QP	LS
Linear	X	78	80	80
Quadratic	X	78	82.1	81.9
Polynomial	X	76	81.6	81.9
R.B.F	1	78	81	81
	0.5	81	83	83
	0.1	89	91.7	91.7
	0.05	97	97	97
	0.02	99.1	99.1	99.1
	0.01	84.9	84.9	84.9
M.L.P	X	78	X	80

표 2. MTTR 감축 결과

Table 2. MTTR reduction by using the proposed method

MTTR감축량(%)	가용률	연간 발전수익(억)
0	88.2	13.9
10	90.8	14.32
20	91.8	14.48
30	92.8	14.64
40	93.8	14.8
50	94.9	14.96

3. 결 론

신재생 에너지원 중 가장 빠르게 성장하고 있는 풍력발전기의 실시간 고장 예측은 이미 시행되어 오고 있었으나, 고장을 미리 예측하여 대비하는 방법은 많

이 발전하지 못해 왔다. 본 논문은 최근 많이 발전하고 있는 패턴인식 방법 중 하나인 SVM 방법을 이용하여 고장과 고장이 아닌 것을 판별하고 각 방법에 대한 예측율을 구하였다. 풍력발전기의 외부환경요인 중 상관관계가 가장 높은 2가지인 온도, 풍속과 고장과의 상관관계 분석을 SVM방법을 이용하여 고장 발생유무를 예측하고 진단함으로써 풍력발전기의 가용률을 증가시키고 전체 발전수익을 증대시키는 결과를 가져올 수 있다는 것을 확인할 수 있었다.

이러한 발전수익의 증가는 최근 풍력발전기의 투자 증대를 위한 자산관리 기법으로도 확장시킬 수 있으며, 이러한 자산관리 기법은 풍력발전기 투자 불확실성에 대한 문제를 해결하여 풍력발전 시장의 성장에도 기여할 수 있을 것이다.

감사의 글

이 논문은 2013년도 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임.
(No. 2011-0017064)

References

- [1] Richard O.Duda, Peter E.Hart and David G. Stork, "Pattern Classification", 2nd Edition, John Wiley & Sons, 2000.
- [2] Jun-Hyun Shin, Seong-Yul Kim, Yun-Seong Lee, Jin-O Kim, "Correlation analysis between wind turbine failures and environmental factors using SVM method and generation benefit evaluation", KIEE Fall conference 2013.
- [3] P. K. Dash, S. R. Samantaray, Ganapati Panda "Fault Classification and Section Identification of an Advanced Series-Compensated Transmission Line Using Support Vector Machine", IEEE TRANSACTIONS ON POWER DELIVERY, VOL. 22, NO. 1, JANUARY 2007.
- [4] Robert Salat, Stanislaw Osowski, "Accurate Fault Location in the Power Transmission Line Using Support Vector Machine Approach", IEEE TRANSACTIONS ON POWER SYSTEMS, VOL. 19, NO. 2, MAY 2004.
- [5] Jianjun Ni, Chuanbiao Zhang, Simon X. Yang, "An Adaptive Approach Based on KPCA and SVM for Real-Time Fault Diagnosis of HVCBs", IEEE TRANSACTIONS ON POWER DELIVERY, VOL. 26, NO. 3, JULY 2011.
- [6] M. F. Yaqub, Iqbal Gondal, Joarder Kamruzzaman, "An Adaptive Self-Configuration Scheme for Severity Invariant Machine Fault Diagnosis", IEEE TRANSACTIONS ON RELIABILITY, VOL. 62, NO. 1, MARCH 2013.

◇ 저자소개 ◇



신준현(申濬鉉)

1986년 8월 12일생. 2012년 한양대 전자시스템공학과 졸업. 현재 동 대학원 전기공학과 석·박사통합과정.

Tel : (02)2220-0347

E-mail : noqlsths@hanyang.ac.kr



이윤성(李允成)

1984년 6월 5일생. 2008년 한양대 전기공학과 졸업. 현재 동 대학원 전기공학과 석·박사통합과정.

Tel : (02)2220-0347

E-mail : lypd@hanyang.ac.kr



김성열(金成烈)

2007년 한양대학교 전자전기컴퓨터공학부 졸업. 2012년 동 대학원 전기공학과 졸업(박사). 2012~2013년 미국 Georgia Institute of Technology, PSCAL 연구원. 현재 계명대학교 에너지공학과 조교수.

Tel : (053)580-5251

E-mail : energy@kmu.ac.kr



김진오(金鎭吾)

1980년 2월 서울대학교 전기공학과 졸업. 1983년 2월 동 대학원 전기공학과 졸업(석사). 1991년 12월 Texas A&M 대학교 전기공학과 졸업(박사). 현재 한양대학교 전기생체공학부 교수.

Tel : (02)2290-0347

E-mail : jokim@hanyang.ac.kr