

# 고분자 전해질 연료전지용 막가습기의 상대습도 추정을 위한 소프트센서 개발

한인수<sup>†</sup> · 신현길  
GS칼텍스 기술연구소

## Soft Sensor Development for Predicting the Relative Humidity of a Membrane Humidifier for PEM Fuel Cells

IN SU HAN<sup>†</sup>, HYUN KHIL SHIN

R&D Center, GS Caltex Corp., 359 Expo-ro, Yuseong-gu, Daejeon 305-380, Korea

**Abstract** >> It is important to accurately measure and control the relative humidity of humidified gas entering a PEM (polymer electrolyte membrane) fuel cell stack because the level of humidification strongly affects the performance and durability of the stack. Humidity measurement devices can be used to directly measure the relative humidity, but they cost much to be equipped and occupy spaces in a fuel cell system. We present soft sensors for predicting the relative humidity without actual humidity measuring devices. By combining FIR (finite impulse response) model with PLS (partial least square) and SVM (support vector machine) regression models, DPLS (dynamic PLS) and DSVM (dynamic SVM) soft sensors were developed to correctly estimate the relative humidity of humidified gases exiting a planar-type membrane humidifier. The DSVM soft sensor showed a better prediction performance than the DPLS one because it is able to capture nonlinear correlations between the relative humidity and the input data of the soft sensors. Without actual humidity sensors, the soft sensors presented in this work can be used to monitor and control the humidity in operation of PEM fuel cell systems.

**Key words** : Soft Sensor(소프트센서), Partial Least Squares(부분최소자승법), Support Vector Machine(지지벡터 머신), Humidifier modeling(가습기 모델링), Humidity(가습도), Fuel cell(연료전지)

### 1. 서 론

고분자전해질 연료전지(polymer electrolyte membrane fuel cell, PEMFC)는 효율과 출력밀도가 높고 공해물질의 배출이 없기 때문에 자동차, 선박, 지게차, 스쿠터 등을 포함한 다양한 운송 수단의 주동력

원으로 활발히 연구되고 있다<sup>1,2)</sup>. 일반적으로 고분자 전해질 연료전지는 막전극접합체(membrane electrode assembly, MEA)와 분리판(bipolar plate)으로 일컫는 두 개의 주요 부품을 차례로 적층하여 제작한다. 이중 막전극접합체는 수소와 산소의 전기화학 반응에 의해 전기를 생산하는 핵심부품으로 촉매 층이 코팅된 전극과 전해질 역할을 하는 고분자막으로 이루어져 있다. 고분자막은 두 전극 사이에 수소 이온을 전달하는 역할을 하며, 탄화수소 계열의 막을 포함한

<sup>†</sup>Corresponding author : ishan1969@gscaltex.com

[ 접수일 : 2014.09.23 수정일 : 2014.10.15 게재확정일 : 2014.10.31 ]

Copyright © 2014 KHNES

다양한 물질을 사용한 고분자막이 개발되어 있으나 PFSA(perfluorosulfonic acid) 계열의 고분자막이 상업적으로 가장 널리 사용되고 있다.

고분자막의 수소 이온 전도도는 막이 함유하고 있는 수분의 함량에 비례한다. 따라서 고분자막은 연료전지가 작동되는 동안 충분한 수분을 함유해야 수소 이온 전도율을 높여 성능을 향상시킬 수 있으며, 고분자막의 dry-out에 의한 내구성 저하를 방지할 수 있다. 고분자막의 함수율 유지를 위해 고분자전해질 연료전지 시스템은 가습기를 장착하는 것이 일반적이다. 가습기는 연료전지에 공급되는 건조 가스의 흐름에 초순수를 가하여 상대습도를 높여 주는 원리로 작동되며, 막가습(membrane humidification), 버블(bubble) 가습, 직접 분사, 스팀 공급 등의 가습 방식이 사용되고 있으나, 수송용 연료전지의 경우 부피가 작고 가습에 필요한 에너지를 적게 사용하는 막가습기가 주로 사용되고 있다<sup>3)</sup>. 한편, 과도한 가습은 연료전지 셀 내에서 플러딩(flooding)을 유발하여 공급 가스가 전극 층으로 도달하는 것을 방해하기 때문에 연료전지의 국부적 성능 저하를 일으킬 수 있다. 따라서 연료전지의 성능과 내구성을 최적으로 유지하기 위해서는 연료전지 내에서 적절한 수준의 습도가 항상 유지될 수 있도록 가습도를 조절하는 것이 매우 중요하다.

막가습기는 막의 양쪽 면에 건조 가스와 습윤 가스(또는 가습수)가 지나가면서 물의 농도와 온도 차이에 의해 물질 및 열전달이 일어나 건조 가스의 수분 함량을 높이고 온도를 올린다. 가습에 사용되는 막은 일반적으로 친수성의 다공성 막을 사용한다. 막가습기는 일반적으로 구조에 따라 원통형과 판형으로 구분할 수 있다. 원통형 막가습기는 고분자막을 속이 빈 중공사막 형태로 가공하여 건조 가스를 튜브 형태의 막의 내부로 통과시키면서 외부로부터 공급되는 수분을 흡수하는 방식으로 가습도를 높인다<sup>3)</sup>. 판형 막가습기는 Fig. 1에 보인 바와 같이 얇은 시트




Fig. 1 Cross-sectional drawing of a plate-type membrane humidifier

형태의 막이 건조 가스와 습윤 가스 사이에 위치하여 건조 가스의 가습도와 온도를 높인다. 막의 양면에 놓인 채널판(channel plate)의 설계 최적화를 통해 판형 막가습기의 가습 성능을 높일 수 있는 장점이 있다. 막가습기의 막을 통해 공급되는 건조 가스와 가습에 사용되는 습윤 가스의 상태(유량, 온도, 압력 및 습도 등)에 따라 가습기를 빠져나오는 가스의 상대습도가 달라진다<sup>4,5)</sup>. 따라서 건조 가스와 습윤 가스의 유량, 온도 및 압력을 적절히 조절해서 연료전지에 공급되는 가스의 상대습도를 최적으로 유지하는 것이 중요하다.

연료전지 시스템의 설계에 따라 고분자전해질 연료전지에 공급되는 공기는 수십~100%의 상대습도를 유지하며, 수소는 가습 없이 공급하거나 수십% 수준의 상대습도를 유지하는 것이 일반적이다. 연료전지의 성능 및 내구성을 향상시키기 위해서는 연료전지에 공급되는 가스의 상대습도가 최적으로 유지되도록 상대습도를 지속적으로 모니터링하고 조절해야 한다. 연료전지 스택에 공급되는 가스의 상대습도(또는 이슬점)는 습도 측정 장치로 모니터링이 가능하나 수백만원에 이르는 고가의 설치비용과 추가적인 공간이 필요하며, 결과적으로 연료전지 시스템 제작 비용 상승을 유발한다. 반면에 소프트센서(soft sensor)

를 사용할 경우 적은 비용으로 유형적 하드웨어 센서 없이도 상대습도를 빠른 시간 내에 예측할 수 있다.

소프트센서는 하드웨어센서와 대비되는 용어로 소프트웨어와 센서의 합성어이다. 소프트센서는 추론센서(inferential sensor) 라고도 불리며, 수식 모델을 사용하여 연속적으로 측정되는 온도, 압력, 유량 등의 입력 데이터로부터 관찰하고자하는 변수를 유형적 하드웨어 없이 예측하는데 사용할 수 있다<sup>6,7)</sup>. 소프트센서는 수식 모델에 기반하고 있기 때문에 예측 정확도를 높이기 위해서는 신뢰성 있는 모델 개발이 선행되어야 한다. 문헌을 통해서 연료전지용 막가습기에 대한 다양한 수식 모델이 수차례 보고된 바 있으나, 대부분 제일원리(first-principle)에 기반을 둔 모델로 예측 정확도를 높이기 위해서는 실험을 통해 모델 파라미터를 튜닝해야 한다<sup>3,5,8)</sup>.

본 논문에서는 판형 막가습기를 통해 연료전지 스택으로 공급되는 공기의 상대습도 추정을 위해 데이터 기반(data-driven) 모델링을 이용한 소프트센서 개발 방법 및 적용 사례를 제시하고자 한다.

## 2. 소프트센서 개발

### 2.1 소프트센서 개발 절차

Fig. 2는 데이터 기반 모델링 기법을 적용한 소프트센서 개발 과정을 도식화한 것이다. 데이터 기반 모델링은 실험을 통해 수집된 데이터를 활용하여 입력변수와 출력변수의 상관관계를 이끌어 내는 기법이다. 따라서 입력변수와 출력변수의 변동 범위가 가습기의 전체 운전 가능한 영역을 전반적으로 포함할 수 있도록 실험을 계획한 후 실험 데이터를 확보해야한다. 확보한 입출력 데이터에 대하여 평균을 빼주고 이를 다시 표준편차로 나누어주는 데이터 mean-centering과 scaling을 먼저 수행한 후에 통계적 기법 등을 활용하여 이상치(outlier)를 제거하여 데이터 전처리를 완료한다<sup>9)</sup>. 전처리를 수행한 데이터는 학습

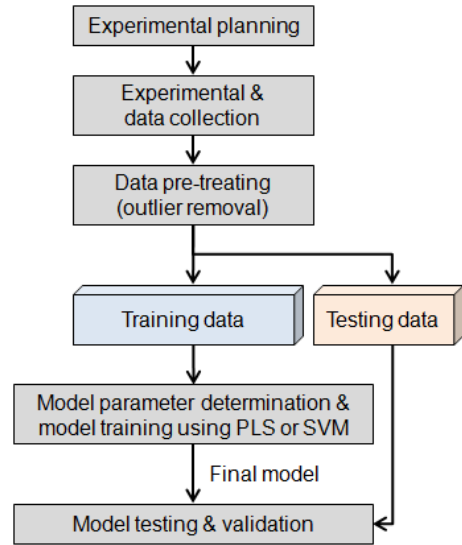


Fig. 2 Soft sensor development procedure based on data-driven modeling methods

데이터(training data)와 검증 데이터(testing data)로 나눈다. 이중 학습 데이터는 대표적인 데이터 기반 모델링 도구인 PLS(partial least square, 부분최소자승법)<sup>9,10)</sup>와 SVM(support vector machine, 지지벡터머신)<sup>11)</sup>과 같은 모델링 알고리즘의 튜닝 파라미터 및 모델 계수들을 결정하여 모델이 측정된 출력변수 값을 잘 설명할 수 있도록 모델을 구성하는데 사용한다. 모델링 과정에서 사용되지 않은 검증 데이터를 이용하여 출력변수 값을 잘 예측하는지 검증 과정을 거쳐 소프트센서에 사용될 최종 모델을 완성한다.

### 2.2 Partial Least Squares

PLS는 실험으로부터 확보한 데이터를 활용하여 입력변수들(독립변수)과 출력변수들(종속변수) 간에 상관관계를 구하는 통계적 모델링 도구로 개발되었으며<sup>11)</sup>, 다양한 산업 분야에 걸쳐 선형 모델을 개발하기 위한 목적으로 활발히 적용되고 있다<sup>12-14)</sup>. 특히, 입력변수들 간에 상관관계가 매우 높아 다중 공선성(multicollinearity)이 존재하거나 데이터에 노이즈가 포함되더라도 일반적인 다중 회귀분석법과 비교하여

신뢰성이 높은 모델을 얻을 수 있는 장점이 있다.

PLS 모델링의 기본 개념은 입출력 변수의 변화를 측정하여 얻은 데이터로부터 형성된 고차원의 데이터 공간에 대하여 각축이 서로 직교하도록 새로운 축을 차례대로 정의하여 저차원의 특성 공간(feature space)으로 압축 투영한 후 각 특성 벡터 간의 최적의 상관관계를 구하는 것이다. 따라서 입력 및 출력 변수 간에 상관관계가 매우 크거나 심지어 특이 값을 갖더라도 신뢰성이 높은 회귀 모델을 얻을 수 있다. 또한, 모델링 결과로부터 얻은 각종 계수들은 모델 해석에 필요한 유용한 정보를 제공한다.

$v$ 개의 입력변수에 대하여  $n$ 번의 샘플링을 거쳐 측정된 입력 데이터는 ( $v \times n$ )의 크기를 갖는  $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3, \dots, \mathbf{x}_n]^T$ 의 행렬로 정리할 수 있으며, 단일 출력변수에 대하여  $n$  번의 샘플링을 거쳐 수집한 출력 데이터는  $\mathbf{y} = [y_1, y_2, y_3, \dots, y_n]^T$ 과 같이 나타낼 수 있다. PLS 모델링의 첫 단계는 데이터 전처리가 수행된 각  $\mathbf{X}$ 와  $\mathbf{y}$ 에 대하여 다음과 같이 rank-one 행렬 또는 벡터의 조합으로 분해하여 outer relation을 구하는 것이다.

$$\mathbf{X} = \sum_{i=1}^a \mathbf{t}_i \mathbf{p}_i + \mathbf{E} \quad (1)$$

$$\mathbf{y} = \sum_{i=1}^a \mathbf{u}_i \mathbf{q}_i + \mathbf{f} \quad (2)$$

여기서,  $a$ 는 압축된 잠재변수(latent variable)의 개수 또는 PLS 차원을 의미한다.  $\mathbf{t}_i$ 와  $\mathbf{u}_i$ 는 각각 입력과 출력 score 벡터를 나타내며, 각 잠재변수  $i$ 에 대하여 순차적으로 계산할 수 있다. 또한  $\mathbf{p}_i$ 와  $\mathbf{q}_i$ 는 loading 벡터와 값으로 각각 변수  $\mathbf{X}$ 와  $\mathbf{y}$ 에 대한 영향의 정도를 나타낸다. 모든 score와 loading 벡터는 잔차(residual) 행렬  $\mathbf{E}$ 와 벡터  $\mathbf{f}$ 를 최소화하는 방향으로 결정된다. 식(1)과 (2)로 표현되는 outer relation으로부터 계산한  $\mathbf{t}_i$ 와  $\mathbf{u}_i$ 의 선형 상관관계를 나타내는

inner relation을 다음과 같이 나타낼 수 있다.

$$\mathbf{u}_i = \mathbf{c}_i \mathbf{t}_i + \mathbf{h}_i, \quad i = 1, 2, 3, \dots, a \quad (3)$$

회귀계수  $\mathbf{c}_i$ 는 각 잠재변수  $i$ 에 대하여 잔차벡터  $\mathbf{h}_i$ 를 최소화하는 방향으로 결정되며, 대각행렬  $\mathbf{C}$ 로 나타낼 수 있다. 식(1)-(3)을 조합하면 다음과 같이 PLS 예측 값  $\hat{\mathbf{y}}$ 를 얻기 위한 모델식을 얻을 수 있다.

$$\begin{aligned} \hat{\mathbf{y}} &= \sum_{i=1}^a \mathbf{t}_i \mathbf{c}_i \mathbf{q}_i^T = \mathbf{T} \mathbf{C} \mathbf{q}^T = \mathbf{X} (\mathbf{P}^T)^{-1} \mathbf{C} \mathbf{q}^T \\ &= \mathbf{X} \mathbf{W} (\mathbf{P}^T \mathbf{W})^{-1} (\mathbf{T}^T \mathbf{T})^{-1} \mathbf{T}^T \mathbf{y} = \mathbf{X} \mathbf{b} \end{aligned} \quad (4)$$

여기서,  $\mathbf{T}(n \times a)$ 는  $[\mathbf{t}_1, \mathbf{t}_2, \mathbf{t}_3, \dots, \mathbf{t}_a]$ ,  $\mathbf{P}(v \times a)$ 는  $[\mathbf{p}_1, \mathbf{p}_2, \mathbf{p}_3, \dots, \mathbf{p}_a]$ ,  $\mathbf{q}$ 는  $[q_1, q_2, q_3, \dots, q_a]$ 를 나타낸다.  $\mathbf{W}(v \times a)$ 는 가중치 행렬  $[\mathbf{w}_1, \mathbf{w}_2, \mathbf{w}_3, \dots, \mathbf{w}_a]$ 이며,  $\mathbf{b}$ 는 모델의 회귀계수  $[b_1, b_2, b_3, \dots, b_v]$ 를 나타낸다. 모델의 잠재변수의 개수( $a$ )는 모델링 과정에서 결정해야 하는 유일한 튜닝 파라미터로 일반적으로 교차타당화(cross-validation)<sup>9)</sup> 과정을 거쳐 결정되는데 최대값은 입력 변수의 수와 같으며, 대체로 이보다 상당히 작은 값을 갖는다. PLS 모델의 주요 계수들(score, loading, weight 및 회귀계수)을 결정하는 알고리즘으로 각 잠재변수에 대하여 순차적인 계산을 수행하는 NIPALS (Nonlinear Iterative Partial Least Squares) 알고리즘을 적용하였다<sup>9)</sup>.

### 2.3 Support Vector Machine

SVM은 Vapnik 등이 분류(classification) 문제<sup>15)</sup>를 해결하기 위한 수단으로 최초로 제안한 후 비선형 회귀문제로 확장되어 다양한 분야의 모델링에 활발히 적용되고 있다. 기존의 다중회귀법, PLS, ANN (artificial neural network, 인공신경망)<sup>16)</sup>과 같은 전통적인 모델링 알고리즘들은 실제함수와 모델 추정값과의 오차를 최소화하는 경험적 위험 최소화 원칙

(empirical risk minimization)에 기반하고 있기 때문에 경우에 따라 over-fitting 문제를 유발하는 단점이 있다. 반면에 SVM은 구조적 위험 최소화 원칙(structural risk minimization)에 기초하고 있기 때문에 일반적으로 모델의 over-fitting 문제에 다소 자유로워 우수한 일반화(generalization) 성능을 보이는 특징을 갖는다<sup>17-19)</sup>. 또한, ANN과 유사한 수준의 예측 성능을 얻을 수 있으며 ANN 모델의 학습 단계에서 겪게 되는 지역최소화 문제를 다소 해결할 수 있는 장점이 있다<sup>12)</sup>.

SVM을 회귀 모델링에 적용하기 위해서는 먼저 데이터 전처리를 완료한 후  $v$ 개의 입력변수에 대하여  $n$ 번의 샘플링을 거쳐 측정된 ( $v \times n$ )의 크기를 갖는 입력 데이터를  $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3, \dots, \mathbf{x}_n]^T$ 의 행렬로 정리한 후 단일 출력변수에 대하여  $n$ 번의 샘플링을 거쳐 수집한 출력 데이터는  $\mathbf{y} = [y_1, y_2, y_3, \dots, y_n]^T$ 으로 정리한다. 입력과 출력 데이터의 상관관계로부터 찾고자 하는 미지의 함수는 다음과 같이 유한개의 파라미터를 갖는 식으로 나타낼 수 있다.

$$\hat{\mathbf{y}} = f(\mathbf{x}) = \sum_{i=1}^n (\alpha_i^* - \alpha_i) K(\mathbf{x}, \mathbf{x}_i) + r \quad (5)$$

여기서,  $\hat{\mathbf{y}}$ 과  $r$ 은 모델 예측 값과 바이어스를 각각 나타내며,  $a$ 와  $a^*$ 은 Lagrange multiplier를 의미한다. Kernel 함수  $K(\mathbf{x}, \mathbf{z})$ 는 입력 공간  $X$ 와 특성 공간을 mapping하는 역할을 하는데, 본 연구에서는 다양한 비선형 회귀 문제에 적용 가능한 다음과 같은 형태의 radial bias 함수를 사용하였다.

$$K(\mathbf{x}, \mathbf{z}) = \exp(-\|\mathbf{x} - \mathbf{z}\|^2 / 2\sigma^2) \quad (6)$$

위 식에서  $\sigma$ 는 Gaussian 분포의 표준편차를 의미한다.

식(5)에 포함된 Lagrange multiplier ( $a$  및  $a^*$ )는 다

음과 같이 제약조건을 갖는 quadratic programming 문제의 해를 구함으로써 결정할 수 있다.

$$\begin{aligned} \min \mathcal{J}(\alpha, \alpha^*) = & \epsilon \sum_{i=1}^n (\alpha_i^* + \alpha_i) \\ & - \sum_{i=1}^n y_i (\alpha_i^* - \alpha_i) \\ & + \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n (\alpha_i^* - \alpha_i) (\alpha_j^* - \alpha_j) K(\mathbf{x}_i, \mathbf{x}_j) \end{aligned} \quad (7)$$

subject to

$$0 \leq \alpha_i^* \leq C \quad (\text{for } i = 1, 2, \dots, n) \quad (8)$$

$$0 \leq \alpha_i \leq C \quad (\text{for } i = 1, 2, \dots, n) \quad (9)$$

$$\sum_{i=1}^n \alpha_i^* = \sum_{i=1}^n \alpha_i \quad (10)$$

여기서,  $C$ 와  $\epsilon$ 은 식(5)로 표현되는 함수의 일반화 정도를 조절할 수 있는 두 개의 주요 조절 파라미터로 각각 capacitance 상수와  $\epsilon$ -insensitive 함수의  $\epsilon$ -insensitive 영역의 크기를 나타낸다. 식(7)-(10)으로 표현되는 최적화 문제의 해는 벡터  $\mathbf{a}$ 와  $\mathbf{a}^*$ 이며, 일반적으로 대부분 0의 값을 갖으며, 0이 아닌 값을 갖는  $\mathbf{a}$ 와  $\mathbf{a}^*$ 가 support 벡터이다. 식(5)에 포함된 바이어스  $r$ 은 support 벡터에 해당하는  $s$ 개의 입출력 데이터 값으로부터 다음 최적화식의 해로부터 구할 수 있다.

$$\begin{aligned} \min L(r) = & \sum_{j=1}^s (y_j - \epsilon \\ & - \sum_{i=1}^n (\alpha_i^* - \alpha_i) K(\mathbf{x}, \mathbf{x}_i) - r)^2 \end{aligned} \quad (11)$$

## 2.4 동적 모델링 방법

2.2와 2.3절에서 설명한 PLS 및 SVM 알고리즘은 일반적으로 막가슴기의 작동이 정상상태(steady-state)에 도달했을 때 확보한 입출력 데이터를 이용한 정상상태 모델링에 적합하다. 따라서 입력 변수의 변화에 따른 가슴도의 동적 변화를 모델링하기 위해서는

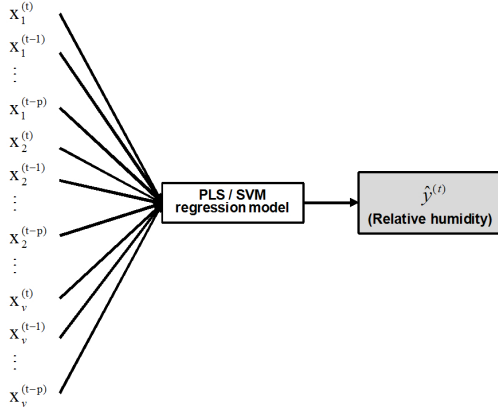


Fig. 3 Dynamic model structure for predicting the relative humidity of the membrane humidifier

동적 모델링을 위한 기법이 결합되어야한다. 본 연구에서는 막가습기의 동적 모델링을 위해 입력변수들의 지연값(lagged value)들로부터 현재의 값을 예측하는 FIR(finite impulse response, 유한 임펄스 응답) 모델<sup>20)</sup>을 PLS와 SVM 모델에 각각 결합한 DPLS(dynamic PLS)와 DSVM(dynamic SVM) 모델을 적용하였다. Fig. 3은 DPLS와 DSVM 모델의 구조를 개략화한 것이다. 각 입력변수에 대하여 p개의 지연 시간을 갖는 측정값이 PLS 또는 SVM 회귀 모델의 입력값으로 사용되어 현재 시간 t에서의 상대습도를 예측한다. 따라서 모델의 총 입력변수(독립변수)의 수는 (v×p)개가 되며, 출력변수(종속변수)는 1개(상대습도)가 된다.

### 3. 실험 방법 및 데이터 수집

모델링 및 소프트센서 검증에 필요한 데이터 수집을 위해 Fig. 4에 보인 가습기 실험 장치를 구성하였다. 실험을 위해 Dufont사의 Nafion 115 막을 사용하여 활성면적 450cm<sup>2</sup>의 5셀로 구성된 판형 막가습기를 제작하였다. 막가습기에 공급되는 건조 공기의 유량은 MFC(mass flow controller)에 의하여 자동 조절되며, 가습기를 통과하면서 함수율이 높아진 공기의 상대습도는 가습도 측정 장치(Vaisala사, Model HMT




Fig. 4 Schematic of the humidifier testing apparatus

Table 1 Manipulated variables of the membrane humidifier and their operation ranges

Manipulated variables	Operation range
Dry air flow rate	20 - 120slpm
Humidifying water pressure	15 - 25kPa
Humidifying water temperature	35 - 70°C

337)에 의하여 실시간으로 측정된다. 가습기를 통과한 공기가 응축되지 않도록 출구 배관은 보온재를 사용하여 충분히 단열을 유지하였다. 가습수는 열교환기에 의하여 설정된 온도로 조절된 후 레귤레이터를 거쳐 설정된 압력으로 가습기에 공급된 후 건조 공기에 열과 수분을 전달한 후 가습기 출구로 배출된다. 측정된 유량, 온도, 압력 및 상대습도는 실시간으로 데이터베이스에 저장된다.

막가습기의 주요 조절변수는 건조 공기의 유량, 가습수의 공급 압력 및 온도이다. 실험 데이터 수집을 위해 이들 조절변수들을 Table 1에 나타낸 막가습기의 작동 범위에 걸쳐 각각 변화시키면서 유량, 온도, 압력 및 상대습도를 측정하였다. 각 센서의 측정값을 5초 간격으로 데이터베이스에 저장하였으며, 240분 동안 모델링에 필요한 학습 데이터를 수집한 후 30분의 추가 실험을 통하여 모델 검증을 위한 데이터를 추가로 확보하였다.

### 4. 결과 및 토론

Table 2는 소프트센서 구성을 위한 PLS와 SVM

모델의 입력변수들과 변동 범위를 나열한 것이다. 모델 구성을 위해 전체 7개의 입력변수를 사용했으며, 이들 변수들은 판형 막기습기의 정상적인 작동을 모니터링하기 위해 일반적으로 최소한 측정되어야 하는 값들이다. 입력변수들과 출력변수(상대습도)에 대하여 측정된 데이터는 mean-centering과 scaling을 수행한 후 이상치를 제거하여 최종적으로 2,819개의 학습 데이터와 347개의 검증 데이터를 얻었다.


DPLS와 DSVM 모델의 총 입력변수의 수는 현재 시간 t에서 각 입력변수의 과거 거동을 반영하는 수준에 따라 달라진다. 입력변수들의 과거 거동을 길게 반영할수록 즉, 지연시간 값을 늘릴수록(p 값의 증가) 일반적으로 모델의 설명력이 증가하지만 모델의 복잡도 또한 증가하는 단점이 있다. 따라서 지연시간 값을 적절한 수준에서 결정해야 한다. 지연시간 값을 결정하기 위해 학습 데이터를 이용하여 지연시간 값을 파라미터로 하는 다수의 DPLS 모델을 구성하였다. Fig. 5는 지연시간의 변화에 따른 DPLS 모델의 설명력을 도시한 그래프이다. 그래프에서 볼 수 있는 바와 같이 지연시간을 증가시킬수록 초기에는 모델의 설명력이 급격히 증가하나 지연시간 값이 30초에서 90.34%에 도달한 후 30초 이후 설명력의 추가 증가율은 0.06%로 매우 미미하다. 이에 따라 지연시간 값을 30초(p=6)로 결정하였으며, 결과적으로 DPLS와 DSVM 모델의 총 입력변수의 수는 42개(v=7, p=6)가 된다.

**Table 2** List of the input variables of the soft sensors and their operation ranges

Variable number	Description (Operation range)
1	Dry air flow rate
2	Dry air inlet temperatur (23.7 - 27.6 °C)
3	Wet air outlet temperature(33.6 - 64.9 °C)
4	Humidifying water inlet temperature
5	Humidifying water outlet temperature
6	Water inlet pressure(15.7 - 49.3kPa)
7	Dry air inlet pressure(3.2 - 29.3kPa)

학습 데이터를 이용하여 교차타당화 과정을 거쳐 모델의 파라미터를 결정한 후 42개의 입력변수를 갖는 DPLS와 DSVM 모델을 최종 완성하였다. DPLS 모델의 파라미터인 잠재변수의 수는 8로 결정되었으며, DSVM 모델의 capacitance 상수와  $\epsilon$ -insensitive 함수의  $\epsilon$ -insensitive 영역의 크기는 각각 0.65와 0.0037 값이 사용되었다.

Fig. 6과 7은 각각 DPLS와 DSVM 모델을 사용한 소프트웨어의 약 30분간의 시간 동안 예측값을 검증 데이터와 비교한 것이다. 그림에 나타난 바와 같이 두 개의 소프트웨어 모두 가습도 측정 장치에 의해 직접 측정된 상대습도와 비교했을 때 특정 구간에서 약간의 오차를 보이지만 전반적으로 측정값에 상당히 근접한 결과를 보여주고 있음을 알 수 있다. DPLS와 DSVM 소프트웨어가 각각 예측한 상대습도의 평균 제곱근 오차(root mean squared error, RMSE)는 각각 1.97%와 1.53%로 DSVM 소프트웨어가 조금 더 우수한 결과를 보였으며, 검증 구간 내에서 최대 오차도 DSVM 소프트웨어가 3.98%로 DPLS 소프트웨어(6.19%) 보다 더 작은 값을 나타냈다. 이는 PLS 알고리즘이 입력변수와 출력변수 간의 선형 관계만을 모델링할 수 있는데 반하여 SVM은 비선형적 변화를 설명할 수 있는 특징이 작용한 것으로 판단된다<sup>12)</sup>.



**Fig. 5** Percent variance captured by PLS models as a function of the time lag in the input variables



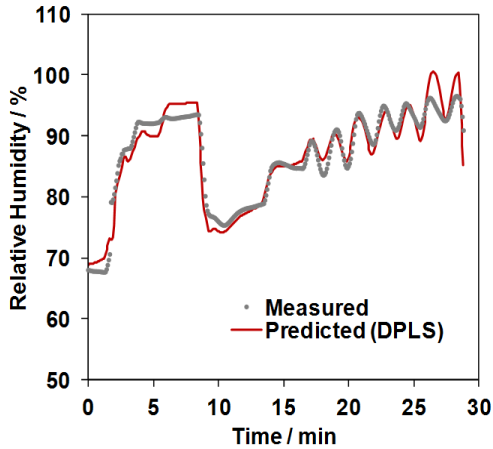


Fig. 6 Prediction result of the relative humidity using the DPLS soft sensor

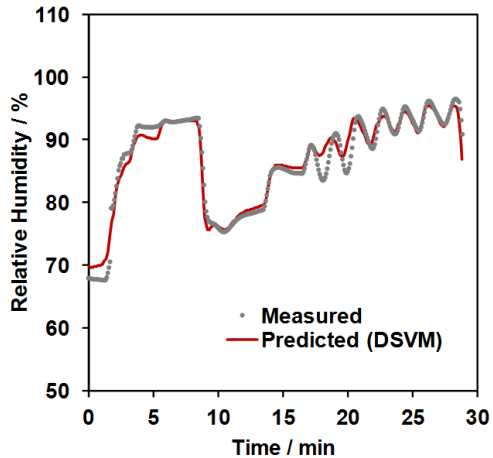


Fig. 7 Prediction result of the relative humidity using the DSVM soft sensor

## 5. 결론

고분자전해질 연료전지용 판형 막가습기의 상대습도 추정을 위한 데이터 기반 소프트센서 개발 방법 및 적용 사례에 대하여 제시하였다. 소프트센서에 사용된 모델은 보존 방정식에 기초한 제일원리 모델을 사용하는 대신에 막가습기 실험으로부터 수집한 데이터를 활용한 데이터 기반 모델을 적용하였다. 데이터 기반 모델링 기법은 비교적 짧은 시간에 모델

을 구축할 수 있으며, 데이터가 충분히 제공될 경우 신뢰성 있는 예측 값을 얻을 수 있는 장점이 있다. 모델 입력변수의 동적 변화를 모델에 반영하기 위해 FIR 모델을 각각 PLS와 SVM과 결합한 DPLS 및 DSVM 모델을 소프트센서 구성에 사용하였으며, 두 모델의 예측 성능을 비교하였다. DPLS 및 DSVM 소프트센서 모두 평균 제공근 오차가 각각 1.97% 및 1.53%로 비교적 우수한 예측 성능을 보였다. DSVM 소프트센서는 SVM 알고리즘이 비선형 거동에 대한 모델링이 가능한 특징으로 인해 DPLS 소프트센서와 비교하여 다소 우수한 성능을 발휘하였다.

본 논문에서 제시한 소프트센서 개발 방법을 적용할 경우, 고분자 전해질 연료전지 시스템의 성능 모니터링 및 내구성 최대화를 위해 필요한 상대습도 측정 장치를 추가로 설치할 필요 없이 저렴한 비용으로 비교적 짧은 시간에 신뢰성 있는 상대습도 예측용 소프트센서의 구성이 가능할 것으로 판단된다.

## 후 기

본 연구는 산업통상자원부 산하 한국산업기술진흥원과 대경지역사업평가원의 대경광역경제권 선도산업육성사업(과제번호 R0001668)의 지원으로 수행되었습니다.

## References

1. I.-S. Han, J. Jeong, B.-K. Kho, C. H. Choi, S. Yu, and H. K. Shin, "Development of a 25 kW-class PEM fuel cell system for the propulsion of a leisure boat", *Trans. Korean Hydrogen & New Energy Society*, Vol. 25, 2014, pp. 271-279.
2. A. Veziroglu and R. Macario, "Fuel cell vehicles: state of the art with economic and environmental concerns", *Int. J. Hydrogen Energy*, Vol. 36, 2011, pp. 25-43.



3. S.-K. Park, S.-Y. Choe, and S.-H. Choi, "Dynamic modeling and analysis of a shell-and-tube type gas-to-gas membrane humidifier for PEM fuel cell applications", *Int. J. Hydrogen Energy*, Vol. 33, 2008, pp. 2273-2282.
4. A. Samimi, S. A. Mousavi, A. Moallemzadeh, R. Roostaazad, M. Hesampour, A. Pihlajamaki, and M. Manttari, "Preparation and characterization of PES and PSU membrane humidifiers", *J. Membrane Sci.*, Vol. 383, 2011, pp. 197-205.
5. S. Park and D. Jung, "Effect of operating parameters on dynamic response of water-to-gas membrane humidifier for proton exchange membrane fuel cell vehicle", *Int. J. Hydrogen Energy*, Vol. 38, 2013, pp. 7114-7125.
6. P. Kadlec, B. Gabrys, and S. Strandt, "Data-driven soft sensors in the process industry", *Computers Chem. Eng.*, Vol. 33, 2009, pp. 795-814.
7. M. Kim, Y.-H. Lee, I.-S. Han, and C. Han, "Clustering-based hybrid soft sensor for an industrial polypropylene process with grad change over operation", *Ind. Eng. Chem. Res.*, Vol. 44, 2005, pp. 334-342.
8. D. Chen, W. Li, and H. Peng, "An experimental study and model validation of a membrane humidifier for PEM fuel cell humidification control", *J. Power Sources*, Vol. 180, 2008, pp. 461-467.
9. P. Geladi and B. Kowalski, "Partial least-squares regression: a tutorial", *Analytica Chimica Acta*, Vol. 185, 1986, pp. 1-17.
10. S. Wold, M. Sjostrom, and L. Eriksson, "PLS-regression: a basic tool of chemometrics", *Chemometrics and Intelligent Laboratory Systems*, Vol. 58, 2001, pp. 109-130.
11. S. R. Gunn, "Support vector machines for classification and regression", University of Southampton, Southampton, UK. 1998.
12. I.-S. Han, C. Han, and C.-B. Chung, "Melt index modeling with support vector machines, partial least squares, and artificial neural networks", *J. Applied Polymer Science*, Vol. 95, 2004, pp. 967-974.
13. I.-S. Han, M. Kim, C.-H. Lee, W. Cha, B.-K. Ham, J.-H. Jeong, H. Lee, C.-B. Chung, and C. Han, "Application of partial least squares methods to a terephthalic acid manufacturing process for product quality control", *Korean J. Chem. Eng.*, Vol. 20, 2003, pp. 977-984.
14. I.-S. Han and C. Han, "Modeling of multistage air-compression systems in chemical processes", *Ind. Eng. Chem. Res.*, Vol. 42, 2003, pp. 2209-2218.
15. B. E. Bosen, I. M. Guyon, and V. N. Vapnik, "A training algorithm for optimal margin classifiers", *Proceedings of the 5<sup>th</sup> Annual ACM Workshop on Computational Learning Theory*, Pittsburgh, PA, 1992.
16. S. A. Kalogirou, "Artificial neural networks in renewable energy systems applications: a review", *Renewable and Sustainable Energy Review*, Vol. 5, 2001, pp. 373-401.
17. C.-C. Chung, S.-F. Su, J.-T. Jeng, and C.-C. Hsiao, "Robust support vector regression networks for function approximation with outliers", *IEEE Trans. Neural Networks*, Vol. 13, 2002, pp. 1322-1330.
18. I.-S. Han, Y.-H. Lee, and C. Han, "Modeling and optimization of the condensing steam turbine network of chemical plant", *Ind. Eng. Chem. Res.*, Vol. 45, 2006, pp. 670-680.
19. Z. Zhong, X. Zhu, and G. Cao, "Modeling a PEMFC by a support vector machine", *J. Power Sources*, Vol. 160, 2006, pp. 293-298.
20. L. Ljung, "System identification: theory for the user", Prentice Hall, New Jersey, USA, 1998.