

주급수 유량의 형상 분류 및 추정 모델에 대한 연구

양학진* · 김성근**† · 최광희***

*동양미래대학교 로봇자동화공학부, **호서대학교 기계공학부, ***한국수력원자력
(2014년 10월 30일 접수, 2014년 12월 5일 수정, 2014년 12월 8일 채택)

A Study of the Feature Classification and the Predictive Model of Main Feed-Water Flow for Turbine Cycle

Hac Jin Yang^{*†} · Seong Kun Kim^{**†} · Kwang Hee Choi^{***}

^{*}School of Robot & Automation, Dongyang Mirae Univ.,

^{**}School of Mechanical Engineering, Hoseo Univ., ^{***}Korea Hydraulics and Nuclear Corporation.

(Received 30 October 2014, Revised 5 December 2014, Accepted 8 December 2014)

요약

터빈 사이클의 성능 상태량을 결정하기 위한 보정 열 성능 분석은 발전소의 향상된 경제성 운전을 위해 요구된다. 본 연구에서는 유용하고 정확한 성능 분석을 위해서 산업 표준인 ASME PTC를 기본으로 하여 성능 데이터를 사용하여 주급수 유량의 영역별 판정 알고리즘을 개발하고 각 영역별 추정 알고리즘을 개발하였다. 추정 알고리즘은 측정 상태량의 상관관계를 기반으로 형상 분류를 제시하고, 이를 기반으로 서포트 벡터 머신 모델링을 이용하여 추정 모델을 구성하였으며, 서포트 벡터 머신 모델링의 우수성을 검증하기 위하여 신경 회로망 모델, 커널 회귀 모델과 비교하였다. 주급수 유량의 형상 분류 및 추정 모델은 터빈 사이클에서 정확한 보정 열 성능 분석을 제공함으로써 향상된 성능 분석에 기여할 것이다.

주요어 : 주급수, 형상 분류, 서포트 벡터 머신, 터빈 사이클

Abstract - Corrective thermal performance analysis is required for thermal power plants to determine performance status of turbine cycle. We developed classification method for main feed water flow to make precise correction for performance analysis based on ASME (American Society of Mechanical Engineers) PTC (Performance Test Code). The classification is based on feature identification of status of main water flow. Also we developed predictive algorithms for corrected main feed-water through Support Vector Machine (SVM) Model for each classified feature area. The results was compared to estimations using Neural Network(NN) and Kernel Regression(KR). The feature classification and predictive model of main feed-water flow provides more practical methods for corrective thermal performance analysis of turbine cycle.

Key words : Main Feed-Water, Feature Classification, Support Vector Machines, Turbine Cycle

1. 서 론

발전 플랜트의 효율적인 운용 및 운전 변수에 대한 성능 분석은 전력 생산의 경쟁력을 위한 필수 관리항

목이며, 터빈과 열 사이클 계통 설비의 성능 분석은 발전소 터빈 사이클의 열 성능 향상을 위하여 정확한 분석 및 평가가 이루어져야 할 중요한 과정이다.

발전 터빈 사이클은 증기 발생기(Steam Generator, SG), 고압터빈(High-Pressure Turbine, HP TBN), 습분 분리기 및 재열기(Moisture Separator and

[†]To whom corresponding should be addressed.

School of Mechanical Engineering, Hoseo Univ.

Tel : 041-540-5811 E-mail : kimskun@hoseo.edu

Reheater, MSR), 저압터빈(Low- Pressure Turbine, LP TBN), 복수기(Condenser), 복수기 펌프(Condenser Pumps), 저압급수 가열기 그룹(Low-Pressure Feed-Water Heaters, LP FWHS), 주급수 펌프(Feed-Water Pumps, FWP), 고압급수 가열기 그룹(High-Pressure Feed-Water Heaters, HP FWHS)을 순환하면서 발전 출력을 생산하는 사이클로 구성된다. 터빈 사이클의 열평형(Heat Balance) 분석은 유량, 온도, 엔탈피, 엔트로피 등의 상태량을 결정하여 발전 효율, 열 소비율(Heat Rate) 및 기기 대표 성능을 분석하기 위한 것으로 발전소 별로 차이가 있으나 각개의 유동 트레인 별로 약 250-300개의 압력, 온도, 유량 등의 데이터들을 측정하여 열평형을 계산하고, 약 1,500개 정도의 상태량 데이터를 구성하여 성능 분석을 하게 된다⁽¹⁻⁷⁾. 기존 연구⁽⁸⁻¹⁵⁾에서는 열평형 분석을 위한 성능 계산 절차 및 분석 시스템을 개발하였으며, 이러한 절차를 기반으로 보정성능을 정확히 결정할 수 있도록 신경 회로망(Neural Network, NN) 추정 모델을 적용하였다.

발전 터빈 사이클 성능 분석을 위한 핵심 측정 항목 중의 하나가 주급수 유량이다. 현장 설비의 노후화 같은 환경 요인에 의하여 이상 측정 상태가 발생할 경우, 기존 연구에서의 주급수 유량 추정 모델은 비효율적이라고 판단되어 본 연구에서는 발전 플랜트에서 실제 측정된 데이터로 판별 영역을 설정하고 각 영역별로 추정 모델을 구성하고자 하였다. 추정 방법으로는 기존의 통계적 학습 방법에서 이용되는 ‘경험적 위험 최소화(Empirical Risk Minimization)’와는 다른 ‘구조적 위험 최소화(Structural Risk Minimization)’를 이용하여 일반화 오차를 감소시키는 기법으로 일반화 능력을 향상 시킬 수 있는 서포트 벡터 머신(Support Vector Machine, SVM) 추정 모델을 비교·적용하고자 하였으며, 또한 정상 상태 및 이상 상태에 대한 상태 판정 모델을 개발하여 추정 모델의 적용성을 높였다.

본 논문의 구성은 다음과 같다. 2장에서는 주급수 유량에 대한 데이터 분석 및 변수간의 상관성을 파악하여, 특징 형상에 대한 판단 기준을 선정한다. 3장에서는 이러한 판단 기준에 의한 상태 판정 모델 알고리즘으로 적용할 서포트 벡터 머신의 개념을 제시하였으며, 4장에서는 상태 판정에 따른 성능 변수를 바탕으로 추정 모델 알고리즘을 적용하여 본 연구에서 제시한 추정 모델의 우수성을 검증한다. 그리고 마치

막으로 5장에서는 결론을 제시한다.

2. 주급수 유량 판별 모델

2.1 주급수 유량 데이터 분석

Fig. 2.1은 터빈 사이클의 성능 분석을 위하여 현장에서 측정하는 입력 데이터 변수 중에서 주요 항목인 주급수 유량의 장기간(160 주기)에 걸친 실제 변화이다.

주급수 유량은 운전기간이 경과함에 따라 오리피스에 생기는 불순물의 축적 등으로 실제 값보다 큰 값으로 측정된다. 이에 따라 열 출력이 과다 계산되므로 안전 기준에 따라 운전 제어 변수를 조정해야하기 때문에, 열 출력이 실제 가능한 최댓값보다 축소된 상태에서 운전되는 비효율적인 결과를 만들어 낸다. 이와 같은 상황이 지속된다고 판단되게 되면 계측기 보정으로 주급수 유량 측정을 강제 보정하게 되며, 그 후에는 보정된 계측에 따라 성능을 측정하고 분석하게 되는 것이 일반적이다. Fig. 2.1에서 A 영역은 정상 상태, B 영역은 앞에서 언급한 것처럼 측정 오류로 인한 강제 보정에 따른 변동 구간, 그리고 C 영역은 강제 보정 이후의 운전 영역으로 발전소 운전 이력 정보를 근거로 판단할 수 있다.

2.2 상관관계의 설정

어느 하나의 측정 데이터가 잘못된 수치를 가지고 있을 때, 그 정보가 사이클의 다른 측정 데이터에서

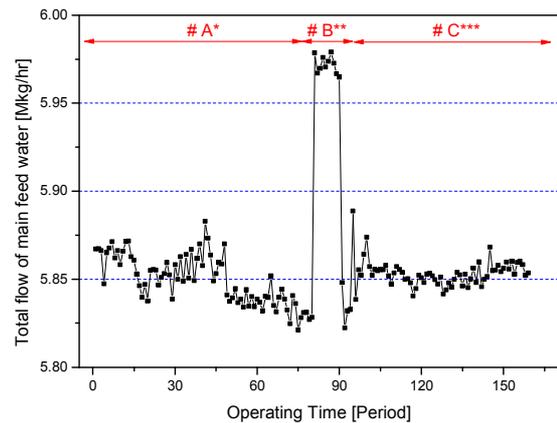


Fig. 2.1. Trends in flow of main feed water. #A: Steady-State Region, #B: Calibration Correcting Region, #C: Corrected-State Region.

Table 2.1 Correlated variables for main feedwater

Factor	Descriptions	Unit
ZHPTBNP	Average Pr. of HP TBN	kg/Cm ² G
ZMSP	Average Pr. of Main Steam Pipe	kg/Cm ² A
ZMSF	Total flow of Main Steam	Mkg/hr
ZFWHT	Average Temp. of Feed Water	℃
ZLTUBT	Average Temp. of Low Temp. Tube	℃
ZHTUBT	Average Temp. of High Temp. Tube	℃
ZBSCALDT	2 nd Heat Power / Delta Temp.	%/℃
ZBDELTD	1 st Power / Delta Temp.	%/℃
ZBTFSPTD	Turbine Power / Delta Temp.	%/℃
ZSFDP	Diff. Pr. of Steam / Diff. Pr. of Feed water	-
ZRCPDP	Average Difference Pr. of RCP	CM _{H₂O} G
ZFWHSGP	FW HDR-SG PR	-
ZBSBD	2 nd Heat Power / 1st Power	-
ZBSBT	2 nd Heat Power / Turbine Power	-
ZGENPO	Normalized Gen. Power	MW _e
ZSTMF1	Steam Flow of train 1	Mkg%/hr
ZSTMF2	Steam Flow of train 2	Mkg%/hr
ZPNFW1	Power Normalized FW flow 1	Mkg%/hr
ZPNFW2	Power Normalized FW flow 2	Mkg%/hr
ZDELT	Delta Temp.	℃
ZMSROPA	Average MSR A Outlet Pr.	kg/Cm ² G
ZMSROPB	Average MSR B Outlet Pr.	kg/Cm ² G
ZMSRTA	Average MSR A Outlet Temp.	℃
ZMSRTB	Average MSR B Outlet Temp.	℃
ZLPTP	Average LP TBN Ext. Pr.	mmHgA

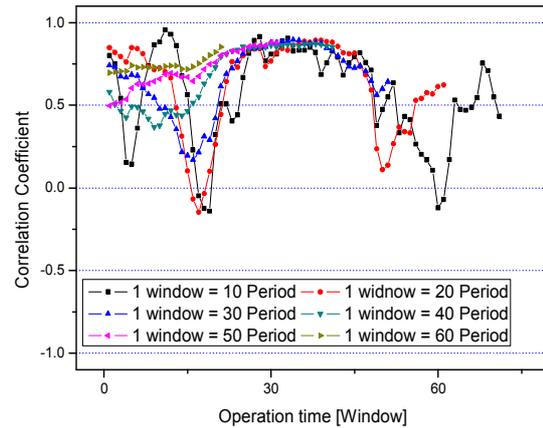
Table 2.2. Weight of correlation coefficient(*r*)

Correlation	Negative	Positive	Weight
None	-0.1 ≤ <i>r</i> ≤ 0.09		0
Small	-0.3 ≤ <i>r</i> < -0.1	0.1 < <i>r</i> ≤ 0.3	0
Medium	-0.5 ≤ <i>r</i> < -0.3	0.3 < <i>r</i> ≤ 0.5	0
Large (Strong)	-0.7 ≤ <i>r</i> < -0.5	0.5 < <i>r</i> ≤ 0.7	Low
	-0.8 ≤ <i>r</i> < -0.7	0.7 < <i>r</i> ≤ 0.8	Middle
	-1.0 ≤ <i>r</i> < -0.8	0.8 < <i>r</i> ≤ 1.0	High

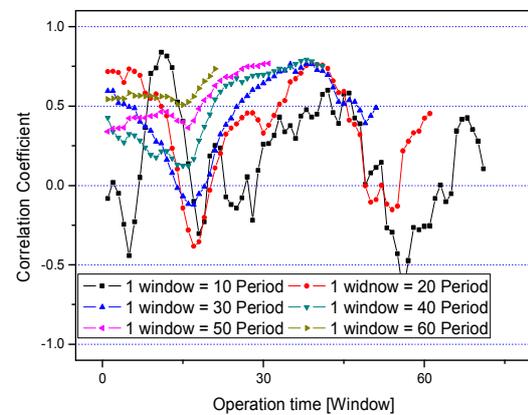
발견될 수 있다는 원칙을 적용하고자 한다. 하나의 정상 측정 데이터의 수치가 변하면, 사이클 유동 네트워크의 특성상 이러한 변화가 다른 측정 데이터의 수치에도 반영될 수밖에 없기 때문이다. 먼저, 주급수 유량과 상관관계가 있다고 판단되는 성능 변수를 측정 데이터나 통계적 상관 관계와 성능 지치서들의 엔지니어링 정보를 활용하여 Table 2.1과 같이 선정하였다.

주급수 유량 및 측정 변수 그룹(Table 2.1)간의 선형적인 관계의 강도를 알아보기 위하여 Pearson product-moment 상관 계수를 사용하여 정의하였다 (식1).

$$r_{ij} = \frac{s_{ij}^2}{\sqrt{s_{ii}s_{jj}}} \text{ where } s_{ij}^2 = \frac{\sum (y_i - \bar{y}_i)(y_j - \bar{y}_j)}{N-1} \quad (1)$$



(a) Factor 'ZFWHT'



(b) Factor 'ZSTMF2'

Fig. 2.2 Comparison with Correlation Coefficients in Steady-Status Region.

이와 같은 상관 계수는 데이터 쌍의 분량이 많을수록 변수간의 영향력을 명확하게 파악할 수 있으나, 현장에서의 여건상, 많은 양의 데이터 쌍을 수집하는 것은 어려운 상황이다. 본 논문에서는 정상 상태의 데이터 쌍(Window)을 10-60의 측정 주기로 모든 변수간의 상관관계를 파악하였으며, Fig. 2.2는 일부를 보여준다. 윈도우 수가 적은 10-30 주기 같은 경우는 상관 계수 변화 폭이 심하여, 상관관계를 표현하기가 적절하지 않지만, 50, 60 주기 같은 경우는 상관 계수 변화가 적고, 상대적으로 일정한 값을 유지하기 때문에 상관관계의 적절한 표현이 가능하다고 판단하였다. 하지만 50 주기인 경우는 Fig. 2.2 (a)처럼 모든 데이터 쌍에서 우수한 항목으로 선정되는 경우도 있고, (b)처럼 전체적인 편차의 크기가 크기 때문에 상관관계의 표현이 어렵다고 판단되는 변수도 다소 나타나게 되어서 60 주기를 윈도우로 설정하였다.

Table 2.3. Classification table of correlated factors

Factor	Status				
	#1	#2	#3	#4	#5
ZHPTBNP	Middle	Low	0	0	Low
ZMSP	0	0	0	0	0
ZMSF	Low	High	Low	0	0
ZFWHT	Middle	Low	0	0	Low
ZLTUBT	0	0	0	0	0
ZHTUBT	0	0	0	0	0
ZBSCALDT	0	Middle	0	0	0
ZBDELTDI	0	Low	0	0	0
ZBTFSPTD	0	0	0	0	0
ZSFDP	0	0	0	Low	0
ZRCPDP	Low	0	0	0	0
ZFWHSGP	Low	Middle	0	0	0
ZBSBD	0	0	0	0	0
ZBSBT	0	0	0	0	0
ZGENPO	Low	0	0	0	0
ZSTMF1	0	High	Low	0	0
ZSTMF2	Low	Middle	0	0	0
ZPNFW1	Low	High	High	High	0
ZPNFW2	0	High	High	High	0
ZDELT	Low	Middle	0	0	0
ZMSROPA	Middle	0	0	0	Low
ZMSROPB	Middle	Low	0	0	Low
ZMSRTA	0	0	0	0	0
ZMSRTB	0	0	0	0	0
ZLPTP	0	0	Low	0	0

Note) High, Middle, Low : Strong factor, 0 : Medium, small and none factors.

2.3 특징 영역 형상 분류

특정 주기를 60 으로 구성된 윈도우는 상관 매칭 표(Table 2.2)에 의하여 우수한 인자를 추출하도록 구성하였다. 상관 매칭표에서는 우수한 상관 계수를 갖는 항목은 가중치를 High, Middle, Low로 부여한 기준표로 세분화하였다.

항목 분류표(Table 2.3)는 Table 2.1에서 선정된 상관 변수들 중에서 기존 데이터와 상관 매칭표에 의하여 가중치를 부여하여 만든 상관관계의 강도를 나타내는 행렬을 의미하며, 항목 분류표의 형상 분류는 앞에서 언급했던 것처럼 크게 3 가지의 영역(정상 상태, 강제 보정 상태, 그리고 보정 후 상태)으로 분류할 수 있으나, 강제 보정 기간이 윈도우 설정 기간(60 주기)보다 상대적으로 짧고, 본 연구에서는 윈도우의 형상에 의하여 형상 분류가 이루어지기 때문에, 윈도우별 표준편차 및 기울기(Fig. 2.3)를 활용하여 5개의 특징 영역으로 형상 분류를 하였으며, Fig. 2.4처럼 특징 영역 형상 분류에 대한 의사결정트리(Decision Tree)를 나타내어, 특징 형상 영역을 분류할 수 있는

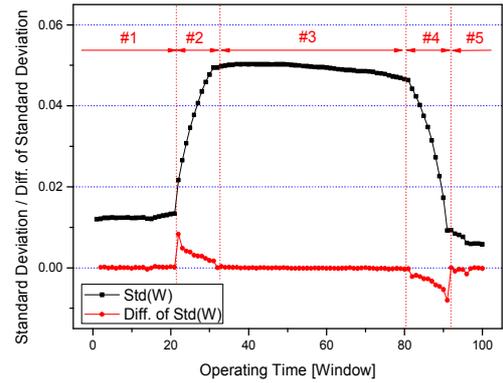


Fig. 2.3. Standard deviation and Differential of Standard deviation for each window.

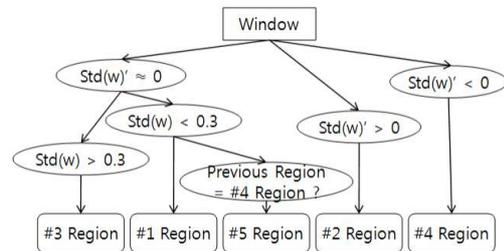


Fig. 2.4. Decision Tree for feature classification

알고리즘을 만들었다.

표준 편차의 기울기가 0에 가깝고, 표준 편차의 크기가 0.03 이상이면, #3 형상으로 분류하였으며, 0.03 이하이면 #1 형상 및 #5 형상으로 분류하였다. 그리고 표준 편차의 기울기가 0보다 크면 #2 형상으로 분류하였으며, 0보다 작으면 #4 형상으로 분류하였다. 이렇게 구분된 형상별 데이터들을 분석하면, #1 형상에서는 정상 상태 영역에서 모든 데이터를 추출하며, #2 형상에서는 추출 데이터의 비중은 작지만 강제 보정 상태 영역에서 데이터가 추출되기 시작하는 영역이다. 그리고 #3 형상에서는 강제 보정 상태 영역에서 추출한 데이터의 비중이 크며, #4 형상 및 #5 형상에서는 강제 보정 상태 영역에서 추출된 데이터의 비중이 점점 줄어들며, 강제 보정 이후 상태 영역에서 추출된 데이터의 비중이 상대적으로 증가하는 구간이다. 이 구분에 따라 주급수 유량 측정 상태에 대한 영역별 판정 구성이 가능하게 되었다.

Fig. 2.5는 앞에서 언급된 의사결정트리를 이용하여 주급수 유량 측정 데이터의 형상 그룹핑의 범위를 보여주는 것이다. 화살표는 형상별 예측하고자 하는 추정값의 영역을 표시한 것이며, 이러한 추정을 위하여 사용된 학습 데이터인 윈도우의 영역은 대시 사각형으로 표시하였다. 학습 데이터는 윈도우의 영역에

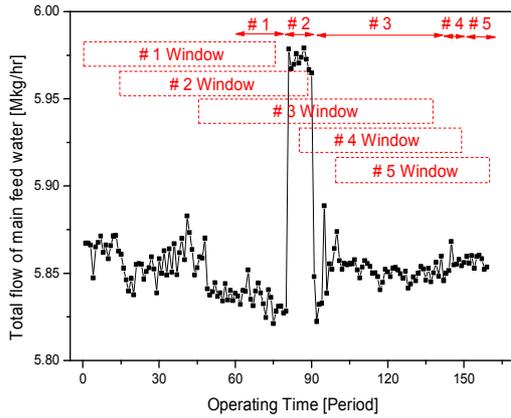


Fig. 2.4. Classification of Feature Region. #1~#5 : Feature, Dashed-rectangle: region of window, Arrow: predicting value.

서 모든 항목을 추출하는 것이 아니라, 추정값의 바로 이전에 측정에 데이터 쌍으로서 항목 분류표 (Table 2.3)에 의거하여 우수한 항목의 데이터만 추출한다.

Table 2.3에서 우수한 항목의 개수는 다소 차이를 보이는 데, 크기는 10여 개의 우수한 항목들을 갖고 있는 형상도 있고, 해당 형상에서만 우수성을 발휘하는 항목도 있었으며, 특정 형상에서만 강도가 낮은 항목도 나타났다.

상관 인자의 선정은 최적의 추정 모델을 설정하기 위함이며, 상관 인자의 적절하지 못한 선택은 계산이 복잡해져서 학습 및 인식 속도가 느려지며, 부적합한 인자의 추가로 인하여 모델의 정밀도가 약화된다(16-18). 이러한 문제점을 간과하고 기존 연구에서는 항목별로 가장 상관도가 높은 3-4개의 항목들을 연관 항목으로 정의하였다(8-13). 본 연구에서는 형상별로 상관 항목을 설정하기 때문에, 다음 형상으로 넘어가는 영역에서는 상관성이 순위가 다소 차이가 있는 것을 알 수 있었으며, 이러한 문제점을 보완하고자 상관성이 우수한 항목별로 그룹으로 설정하고, 높은 순위별로 4번째 항목이 포함하는 그룹까지 우수 항목으로 설정하였다. 즉, #1 형상에서는 Middle 그룹까지, #2 형상에서는 High 그룹까지, #3 형상, #4 형상 그리고 #5 형상에서는 Low 그룹까지 우수 항목으로 설정하였다.

Table 2.3과 같은 항목 분류표와 비교하여 특징 영역 형상이 분류되면, 상관 행렬에서의 해당 영역 형상에 대한 우수한 상관항목 리스트를 이용하여 분리된 데이터만을 학습 데이터 입력 항목으로 구성하였다.

3. 추정 알고리즘

3.1 서포트 벡터 머신

주급수 유량을 예측하기 위한 비선형 모델로서, 본 연구에서는 여백을 최대한 하여 일반화 능력을 극대화할 수 있는 서포트 벡터 머신 회귀 모델(19, 20)을 사용하였으며, 이러한 모델을 사용하기 위하여 학습 데이터를 구성한다. 학습 데이터는 60개의 데이터 쌍으로 구성된 윈도우와 추정값 1 주기로 이루어졌으며, 윈도우의 데이터 순번은 랜덤으로 재배치한다.

SVMs의 최적 회귀 모델 $\hat{f}^*(\bar{x}) = \bar{w}^* \cdot \bar{x} - b^*$ 을 구하기 위한 최적화 모델은 식(2) 와 식(3)과 같이 구성된다.

$$\min \Phi(\bar{w}, b, \xi, \xi') \tag{2}$$

$$\min_{\bar{w}, b, \xi, \xi'} \frac{1}{2} \bar{w} \cdot \bar{w} + C \sum_{i=1}^l (\xi_i + \xi'_i)$$

$$y_i - \hat{f}(\bar{X}_i) \leq \xi_i + \epsilon \tag{3}$$

$$\hat{f}(\bar{X}_i) - y_i \leq \xi'_i + \epsilon$$

$$0 \leq \xi_i, \xi'_i$$

$$\text{for } i = 1, \dots, l \quad \hat{f}(\bar{x}) = \bar{w} \cdot \bar{x} - b$$

여기서 슬랙변수 ξ (Slack Variable)는 데이터의 샘플 위치가 옳게 분류되었는지 판별할 수 있는 변수이며, C는 사용자가 설정해야 하는 매개 변수로서 여백을 될 수 있는 한 크게 하며, 동시에 $0 < \xi$ 인 샘플의 수를 될 수 있는 한 적게 하는 두 가지 목적 중 어느 것에 비중을 둘지를 결정하는 변수이다.

라그랑지 최적 모델은 구속조건을 포함하여 다음과 같이 구성된다.

$$\max_{\alpha, \alpha', \beta, \beta'} \min_{\bar{w}, b, \xi, \xi'} L(\bar{\alpha}, \bar{\alpha}', \bar{\beta}, \bar{\beta}', \bar{w}, b, \xi, \xi') \tag{4}$$

$$= \max_{\alpha, \alpha', \beta, \beta'} \min_{\bar{w}, b, \xi, \xi'} \left(\frac{1}{2} \bar{w} \cdot \bar{w} + C \sum_{i=1}^l (\xi_i + \xi'_i) \right.$$

$$\left. - \sum_{i=1}^l \alpha_i (\xi_i + \epsilon - y_i + \hat{f}(\bar{x}_i)) \right.$$

$$\left. - \sum_{i=1}^l \alpha'_i (\xi'_i + \epsilon - \hat{f}(\bar{x}_i) + y_i) \right.$$

$$\left. - \sum_{i=1}^l \beta_i \xi_i - \sum_{i=1}^l \beta'_i \xi'_i \right)$$

또한, 듀얼 최적화 모델은 식(5)와 같이 정해지며, 최적 서포트 벡터 머신 회귀 모델은 식(6)을 사용하여 구성되었고, 대표적인 커널 함수인 방사 기저 함수 커널(Radial Basis Function Kernel)을 적용하였다.

$$\max_{\bar{\alpha}, \bar{\alpha}'} \Phi'(\bar{\alpha}, \bar{\alpha}') = \tag{5}$$

$$\max_{\bar{\alpha}, \bar{\alpha}'} \left(-\frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l (\alpha_i - \alpha_i') (\alpha_j - \alpha_j') \bar{x}_i \cdot \bar{x}_j \right. \\ \left. + \sum_{i=1}^l y_i (\alpha_i - \alpha_i') - \epsilon \sum_{i=1}^l (\alpha_i + \alpha_i') \right)$$

$$\hat{f}(\bar{x}) = \bar{w}^* \cdot \bar{x} - b^* \tag{6}$$

$$= \sum_{i=1}^l (\alpha_i^* - \alpha_i'^*) \bar{x}_i \cdot \bar{x}$$

$$- \frac{1}{l} \sum_{i=1}^l \sum_{j=1}^l (\alpha_i^* - \alpha_i'^*) \bar{x}_i \cdot \bar{x}_j - y_j$$

4. 검증

Fig. 4.1는 특징 영역 판별 기반 추정 알고리즘에 대한 전반적인 요약 흐름도로서, 해당 윈도우에 대한 상관 계수를 계산하고, 상관 매칭표에 의하여 우수한 항목을 선별하여, 항목 분류표와 비교한다. 그리고 형상이 설정되면, 해당 형상에 대한 항목 분류표의 우수한 항목 리스트를 바탕으로 윈도우의 학습 데이터를 추출한다. 그리고 추출된 데이터를 이용하여 학습하고, 추정 모델 알고리즘인 서포트 벡터 머신 모델을 통하여 추정 값을 추출하였으며 신경 회로망 및 커널 회귀(Kernel Regression, KR) 모델을 사용한 추정 결과와도 비교하여 적용성을 검증하였다.

Fig. 4.2는 형상별 적합률을 나타내고 있다. 각각의 데이터 쌍에 대한 우수 항목 및 그렇지 못한 항목에 대한 가중치(우수 항목 = 1, 아닌 항목 = 0)를 부여하고, 항목 분류표(Table 2.3)와 비교하여 동일하면 참(1), 동일하지 못하면 거짓(0)으로 해당 영역에 대한 형상의 적합률을 계산한 것이다. 여기서, 적합률을 계산할 때 우수하지 못한 항목도 항목 분류표와 동일하면 참으로 부여하였다.

#1 영역이 시작하는 구간에서는 항목 분류표의 #1 형상에 대한 항목 분류(우수 항목과 그렇지 못한 항목으로 분류)와 95% 이상의 비슷한 경향으로 보이고 있으며, #2 형상의 항목 분류와도 50% 정도의 경향을 보이고 있다. 하지만 #1 영역이 끝나가는 부분에서는 #1 형상의 항목 분류와 적합률이 낮아지며, #2 형상의 항목 분류와 적합률이 증가하였으며 #2 영역이 시작하는 구간부터는 #2 형상의 항목 분류와의 적합률이 90% 이상을 보이고 있다. 이렇듯 각각의 영역별 새로 시작하는 구간 및 끝나는 구간에서 상대적으로 적합률이 낮으며, 형상 분류에 대하여 오판하는 경우도 있었다. 특히 #5 영역이 시작하는 구간에서는

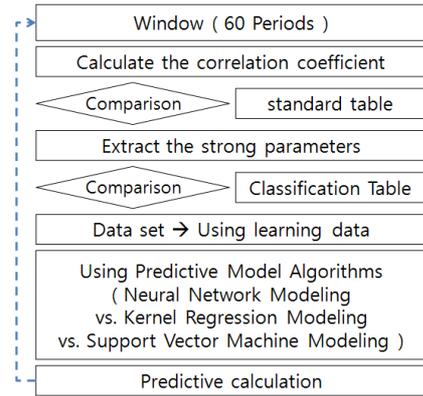


Fig. 4.1. Flow-Chart of the predictive algorithms.

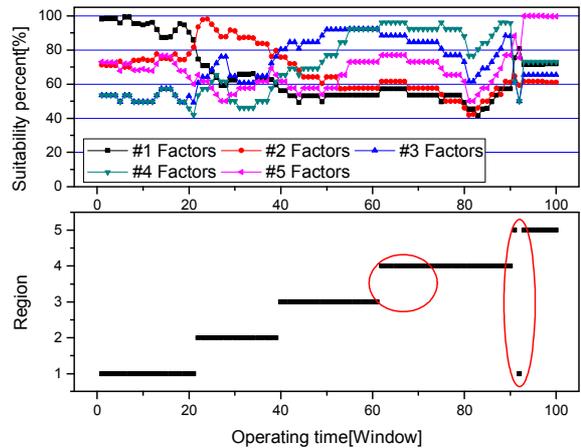


Fig. 4.2. Suitability percent of window.

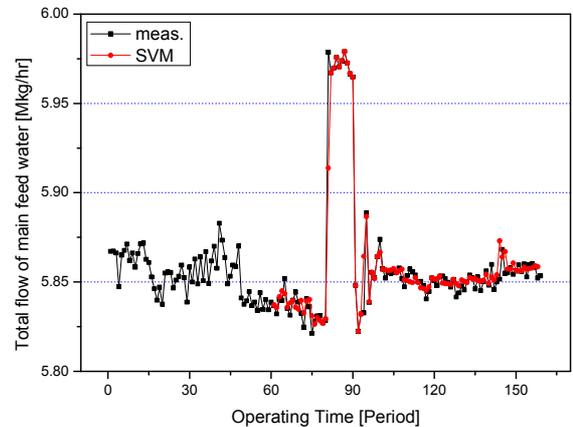


Fig. 4.3. Calculating Result through Support Vector Machine.

낮은 적합률을 보이며, #1 형상으로 오판하는 경우(타원 표시)도 발생하였다.

서포트 벡터 머신에 의한 추정 값은 Fig. 4.3과 같이 나타났다. 대체적으로 오차가 1% 미만으로 나타났으며, 측정값을 정확하게 추정하는 값(0.1% 미만)들도 상당수가 있었다. 하지만 몇 개의 경우는 다소

Table 4.1 Comparison with measurement data and predictive calculation

No.	Reg.	Meas. [Mkg/hr]	SVM	NN	KR
			Calc. [Mkg/hr]	Calc. [Mkg/hr]	Calc. [Mkg/hr]
			Err. [Mkg/hr]	Err. [Mkg/hr]	Err. [Mkg/hr]
1	#1	5.83687	5.83705	5.83852	5.83951
			-0.00018	-0.00165	-0.00264
2	#1	5.83875	5.83470	5.79565	5.84348
			0.00405	0.04310	-0.00473
3	#1	5.82113	5.83114	5.84955	5.83647
			-0.01001	-0.02842	-0.01534
4	#2	5.97860	5.91382	5.79345	5.83969
			0.06478	0.18515	0.13891
5	#2	5.96480	5.96477	5.827	5.91079
			0.00003	0.1378	0.05401
6	#2	5.83281	5.86434	7.29846	5.83710
			-0.03153	-1.46565	-0.00429
7	#3	5.85215	5.85680	5.88124	5.85726
			-0.00465	-0.02909	-0.00511
8	#3	5.85531	5.85521	5.97623	5.85552
			0.00010	-0.12092	-0.00021
9	#3	5.85718	5.85021	5.96893	5.85163
			0.00697	-0.11175	0.00555
10	#4	5.84975	5.84898	5.83618	5.85623
			0.00077	0.01357	-0.00648
11	#4	5.84149	5.84910	5.84072	5.85034
			-0.00761	0.00077	-0.00885
12	#4	5.85238	5.85178	5.85685	5.85560
			0.00060	-0.00447	-0.00322
13	#5	5.85161	5.87298	5.90943	5.85008
			-0.02137	-0.00578	0.00153
14	#5	5.85487	5.85710	5.84812	5.86563
			-0.01223	0.00675	-0.01076
15	#5	5.85574	5.85643	5.85191	5.85584
			-0.00069	0.00383	-0.00010

큰 오차가 발생하였다. 모든 영역에서의 평균 오차는 0.38% 이며, #1 영역에서는 0.38%, #2 영역에서는 0.52%, #3 영역에서는 0.28%, #4 영역에서는 0.26%, 그리고 #5 영역에서는 0.45%로 나타났다.

Table 4.1은 서포트 벡터 머신, 신경 회로망 그리고 커널 회귀 모델을 이용한 추정 모델의 결과로서, 일부분만 보여주고 있으며, 오차가 크게 발생한 몇몇 데이터를 포함하였다. 이러한 값들은 대부분이 #2 형상과 #5 형상에서 나타났는데, 오차가 가장 큰 값은 측정값이 5.9786 Mkg/hr이었으나 추정 값이 5.9138 Mkg/hr으로 나타난 곳으로서 강제 보정이 시작되는 영역이었다. 이렇게 크게 발생하는 오차에 의하여 #2 형상에서 평균 오차가 커진 것을 알 수 있었으며, #5 형상에서는 전반적으로 오차가 크게 나타나서 평균 오차율이 커진 것을 알 수 있었다.

또한, 비선형 모델에 대한 많이 연구된 신경회로망 모델 및 커널 회귀 모델을 이용하여 추정값을 비교해 보았다. 신경 회로망 모델인 경우, 활성화 함수는

Sigmoid 함수를 사용하였으며, 은닉층은 단층, 뉴런 수는 입력층의 1.5배, 학습률은 0.1로 설정하였다. Table 4.1에서 보는 것과 같이 특정 값에서는 서포트 벡터 머신 모델보다 오차가 작지만, 전반적으로 큰 오차가 발생하였으며, 특히 #2 형상에서는 추정 값이 수렴되지 않고, 큰 오차값을 나타나게 되었다. 커널 회귀 모델인 경우는 가우시안 커널을 사용하였으며, 학습 데이터 중 마지막 데이터와 비교하여 커널 폭 (Bandwidth)를 설정하였으며, Table 4.1에서 보는 것과 같이 서포트 벡터 머신 모델과 비슷한 오차율을 보이고 있으나 #2 영역이 시작되는 구간에서 다소 큰 오차가 발생하였다. 이러한 비교결과로 서포트 벡터 머신이 신경 회로망이나 커널 회귀 모델보다 적용성이 우수함을 판단할 수 있었다.

5. 결론

터빈 사이클의 성능 상태량을 결정하기 위한 보정 열 성능 분석은 발전소의 향상된 경제성 운전을 위해 필요하다. 본 연구에서는 정확한 보정 분석을 위하여 주급수 유량의 형상을 판별하며 보정하는 추정 모델을 서포트 벡터 머신을 사용하여 구성하였으며, 주급수 유량의 측정 오류로 발생할 수 있는 보정 성능의 오류 가능성을 축소할 수 있도록 구성하였다.

측정치 대비 추정치를 보면, 대체적으로 오차가 1% 미만이었으나, 몇몇 데이터의 오차가 크게 나타나는 것을 알 수 있었으며, 이러한 데이터는 #2 및 #5 형상에서 발생하였으며, 이러한 오차는 다음과 같은 문제에서 발생한다.

- 1) 영역이 시작하는 구간에서도 해당 형상에 대한 우수한 인자를 선별하지만, 학습 데이터는 이전 구간의 데이터이므로, 우수 인자가 반영된 데이터가 아닐 수 있으므로 추정 알고리즘의 적용에서 오차가 발생할 수 있다.
- 2) 측정 변수 그룹의 항목 간에 비선형 모델로 선정하였지만, 선형 관계의 강도를 나타내는 상관 계수를 이용하여 항목 분류표를 만들었으며, 상관 매칭표에 의한 가중치를 부여할 때 0, High, Middle, Low로서의 판별을 하면서 발생하는 오류 및 이를 토대로 계산되어지는 추정 알고리즘에서 발생하였다고 본다. 이러한 문제점은 예를 들어, #5 영역에서 우수한 인자를 추출할 때, 4개의 우수한 인자를 추출하지만, 모든 항목이

Low 그룹에 속하기 때문에 다른 그룹에 비하여 강도가 낮으며, 이러한 항목만을 이용하여 학습 데이터를 구성하고, 추정치를 계산함으로써 오차가 상대적으로 크게 발생하였다.

따라서 이러한 문제점을 해결하기 위하여, 형상 분류에 따른 새롭게 시작되는 영역에서의 학습 데이터 추출 방법, 상관 매칭표에서 세분화된 가중치를 부여하여 적용하는 방법에 대하여 지속적인 연구가 필요하다고 판단된다.

후 기

본 연구는 호서대학교의 지원과 한국수력원자력(주)의 지원으로 수행되었으며, 이에 관계자 여러분들께 감사드립니다.

References

1. American Society of Mechanical Engineers, 1976, Performance Test Code 6, "Steam Turbines."
2. American Society of Mechanical Engineers, 1982, Performance Test Code 6A, "Appendix A to Test Code for Steam Turbines."
3. American Society of Mechanical Engineers, 1978, Performance Test Code 12.1, "Closed Feed Water Heaters."
4. American Society of Mechanical Engineers, 1983, Performance Test Code 12.2, "Steam Condensing Apparatus.", USA, pp. 337-350.
5. Munchausen, J. H., 1995, "EPRI Performance Enhancement Program," Proceedings of the American Power Conference, USA, pp. 519-521.
6. Spencer, R.C., Cotton, K.C. and Cannon, C.N., 1974, "A Method for Predicting the Performance of Steam Turbine-Generators, 16,500KW and Larger," General Electric Co. Report.
7. British Electricity International, 1991, "Modern Power Station Practice: Volume G Station Operation and Maintenance"
8. Bae, H., Kwon, S.I., Lee, J.K., Song, C.K., Kim, S.S., 2002, "The Fault Diagnosis using Two-Steps Neural Networks for Nuclear Power Plants", KIIS, Vol. 12, No. 2, pp. 129-134.
9. Kim, Y.S., Lee, D.H., Kim, S.K., 2010, "Rotating Machinery Fault Classification Using Support Vector Machines with Optimal Features for Each Fault Type", RD-KSME, Spring Conference, pp. 84-91.
10. Kim, S.K. and Choi, K.H., 2001, "Development of Performance Analysis System (NOPAS) for Turbine Cycle of Nuclear Power Plant", Journal of Korean Nuclear Society, Vol. 33, No. 1, pp. 211-218.
11. Kim, S.K. and Choi, K.H., 2001, "Development of Performance Analysis Methodology for Nuclear Power Plant Turbine Cycle using Validation Model of Performance Measurements", Journal of KSME, Vol. 24, No. 12, pp. 1625-1634.
12. Kim, S.K. and Choi, K.H., 2000, "Thermal Performance Analysis System Based on Measurement Validation for Nuclear Power Plant," 4th KSME-JSME Thermal Engineering Conference.
13. Korea Hydraulic and Nuclear Co., 2003, "User's Guide for PERUPS, Programmer's Guide for PERUPS, Technological Guide for PERUPS".
14. Korea Hydraulic and Nuclear Co., 2003, "Development of Thermal Performance Analysis Computer Program on Turbine Cycle of Yongwang 3,4 Units", Research Report Korea Hydraulic and Nuclear Co.
15. Kim, S.K. and Choi, K.H., 2005, "PERUPS (PERformance UPgrade System) for On-Line Performance Analysis of Turbine Cycle of Nuclear Power Plant", Journal of Korean Nuclear Society, Vol. 37 No. 2, pp. 165-172.
16. Roberto Battiti, 1994, "Using Mutual Information for Selecting Features in Supervised Neural Net Learning", IEEE Transactions on Neural Networks, Vol. 5,

- No.4, pp. 537-550.
17. Andrew D. Back, Thomas P. Trappenberg, 1999, "Input Variable Selection Using Independent Component Analysis", International Joint Conference on Neural Networks, IJCNN '99, Vol. 2, pp. 989-992.
 18. T.M.K.G. Fernando, H.R. Maier, G.C. Dnady, 2009, "Selection of input variables for data driven models: An average shifted histogram partial mutual information estimator approach", Journal of Hydrology, Vol. 367, pp. 165-176.
 19. C.J.C. Burges, 1998, "A Tutorial on Support Vector Machines for Pattern Recognition", Data Mining and Knowledge Discovery, Vol.2, pp.121-167.
 20. Nello Cristianini, John Shawe-Taylor, 2000, "Introduction to Support Vector Machines and other Kernel-based Learning Method", Cambridge University Press.