

뉴로퍼지학습 알고리듬을 이용한 연소상태진단

이태영[†] · 김성환^{*} · 이상룡^{**}

(2000년 8월 2일 접수, 2002년 2월 14일 심사완료)

Flame Diagnosis Using Neuro-Fuzzy Learning Algorithm

Tae Young Lee, Seong Hwan Kim and Sang Ryong Lee

Key Words: Back-Propagation(역전파), Neuro-Fuzzy Algorithm(뉴로-퍼지 알고리듬), Flame Diagnosis (화염진단), Burner(버너), Combustion(연소).

Abstract

Recent trend changes a criterion for evaluation of burners that environmental problems are raised as a global issue. Burners with higher thermal efficiency and lower oxygen in the exhaust gas, evaluated better. To comply with environmental regulations, burners must satisfy the NO_x and CO regulation. Consequently, 'good burner' means one whose thermal efficiency is high under the constraint of NO_x and CO consistency. To make existing burner satisfy recent criterion, it is highly recommended to develop a feedback control scheme whose output is the consistency of NO_x and CO. This paper describes the development of a real time flame diagnosis technique that evaluate and diagnose the combustion states, such as consistency of components in exhaust gas, stability of flame in the quantitative sense. In this paper, it was proposed on the flame diagnosis technique of burner using Neuro-Fuzzy algorithm. This study focuses on the relation of the color of the flame and the state of combustion. Neuro-Fuzzy learning algorithm is used in obtaining the fuzzy membership function and rules. Using the constructed inference algorithm, the amount of NO_x and CO of the combustion gas was successfully inferred.

1. 서 론

최근 세계적으로 관심이 커지고 있는 대기환경 보호 문제로 산업용 보일러나 자동차의 엔진, 가스터빈 등에서 배출되는 연소 후 대기오염물질의 규제문제가 사회적인 관심사로 대두되고 있다. 따라서 열기관 설계 및 운전 시 종래의 주된 관심사였던 에너지 효율의 극대화 이외에 연소 시 발생되는 대기오염물질의 배출을 최소화시키는 것도 중요한 변수로 대두되고 있다.

연소 중 발생하는 오염물질의 양은 연료 및 연소상태에 영향을 받는다. 배기ガ스 중에 포함된 대기오염물질 중 아황산가스(SO_x)와 같이 연소 상태에 크게 의존하지 않고 연료 중 황(sulfur)성분에 의해 배출량이 결정되는 것이 있는 반면 질산화물(NO_x), 일산화탄소(CO), 미연탄화수소(unburned hydrocarbon), 매연(soot) 등과 같이 연소조건에 크게 의존하는 것들이 있다. 질산화물, 일산화탄소, 미연탄화수소, 매연 등의 배출은 연소조건의 적절한 제어에 크게 의존한다. 화염의 온도와 연소 중 과잉산소량이 증가함에 따라 질산화물의 배출량도 증가하는데 일반적으로 적당한 공연비에 도달하면 화염온도가 최고조에 도달하여 열적반응에 의한 질산화물의 생성량이 극대화된다. 그리고 이와 반면에 일산화탄소, 미연탄화수소, 매연 등은 연소가 불완전할 때 발생되므

[†] 책임저자, 회원, 구미1대학 차량기계과
E-mail : tylee@kumi.ac.kr

TEL : (054)440-1274 FAX : (054)440-1270

^{*} 경북대학교 대학원 기계공학과

^{**} 회원, 경북대학교 기계공학부

로 이론공연비보다 공기가 다소 부족한 상태로 연소상태가 유지될 때 배출량이 증가하게 된다. 따라서 대기오염 방지측면에서는 적절한 연소제어를 통해 열기관의 열효율을 극대화하는 운전조건에서 질산화물의 배출량과 일산화탄소, 미연탄화수소, 매연 등의 배출량을 최소로 하는 운전조건을 유지해야 한다. 최적의 연소조건을 유지하면서 화염의 온도를 낮추는 방법은 동일한 연료 사용량 조건에서 화염의 형태를 가능한 넓게 분포시키는 것인데 이렇게 할 경우 화염의 안정성이 낮아지는 위험부담이 있게 되어 화염제어측면에서 각별한 주의가 필요하게 된다.

고전적인 베너운전 방식은 숙련된 작업자가 육안으로 화염의 상태를 판정한 후 제시하는 제어명령에 따라 운전되었다. 이러한 베너 제어방식은 정량적 분해능이 없기 때문에 이상연소를 조기에 발견할 수 없고, 최적연소 상태에서의 운전도 불가능하다. 그리고 작업자가 바뀌었을 때 숙련된 작업자의 경험이 전수될 수 없다는 점도 큰 문제점으로 지적된다. 따라서, 보다 적극적인 연소진단 관련 기술의 실용화 개발이 시급하다.

일본의 미쓰비시 중공업에서 배기ガ스중의 NOx, CO의 양과 RGB 칼라모델과의 상관관계를 규명하기 위한 연구가 있었으며, R/B의 비율과 CO와 높은 상관관계가 있음을 발표하였다.⁽¹⁾

한편, 국내에서는 이태원⁽²⁾ 등이 내연기관의 온도측정과 분진(soot) 농도 계측에 영상처리 기법을 응용하였으나 산업용 베너의 연소 상태를 진단하기 위한 컬러 영상처리 기법의 적용에 관한 연구 보고는 없는 실정이다.

김성환⁽⁴⁾은 배출가스가 생성되기까지의 중간과정에서 발생하는 화학반응의 발광중 가시광 영역에서 발생하는 발광에 초점을 맞춰, 이들을 측정하고 컬러 영상처리와 이산신호 해석기법을 이용하여 공해물질의 발생농도와의 상관관계를 구축하고자 하였다. 김성환⁽⁴⁾은 베너의 연소상태를 진단하기 위해 컬러 영상처리 기법을 사용하여 HSI Color Model의 특정 Hue Level과 배기ガ스중의 NOx, CO, Soot량 등의 관계에 대하여도 연구하였다.

이전의 연구^(1~4)에서는 컬러영상속에 포함되어 있는 특정 파라메타와 연소상태를 나타내는 배기ガ스중의 NOx, CO 등의 관계를 선형관계식으로 모델링되었다. 그러나 연소상태에 영향을 주는 여러 가지 변수들에 의한 복잡한 관계식을 모델

링하지 못하였으며 한가지 변수에만 영향을 받는다는 가정 하에서 이루어졌다.

이러한 상황을 배경으로 본 연구에서는 벤치버너를 사용하여 화염을 구성하고, 화염의 직접적인 관찰과 해석을 통한 연소제어에 필요한 정보를 제공하는 방법을 규명하는 것을 연구범위로 하며 본 연구활동을 통해 화염해석 알고리듬을 완성하고자 한다. 이러한 알고리듬은 화염감시용 Hardware와 결합되어 화염감시/진단 및 연소제어 시스템을 구성하는 것을 목표로 한다.

본 연구는 컬러 영상 속에 포함되어 있는 여러 가지 파라미터들을 추출하여 상관관계가 높은 파라미터들을 입력변수로 사용하고 베너의 배기 가스 중의 NOx 농도, CO 농도, Soot 농도 등을 각각 출력변수로 하는 퍼지추론 시스템을 구성하였다. 실험을 통하여 얻은 상관관계를 신경회로망을 이용하여 학습시키는 뉴로퍼지 알고리듬을 이용하여 다카카-수게노 모델로 유도하였다.

신경회로망을 이용한 학습 알고리듬은 학습조건이 실제 운전조건과 같아야 하며 모델링된 관계식이 적관적으로 알아볼 수 있는 관계식의 형태가 아니라는 단점은 있지만, 선형관계식을 쉽게 구하기 힘든 경우나 모델링이 힘든 대상체의 상관관계를 구하는데 있어서 유용하게 사용되는 기법이다. 본 연구에서도 그 선형관계식에 의한 상관관계를 구하고자 하였으나 오차의 범위가 너무 커서 상관관계를 구하기 힘든 점을 감안하여 신경회로망에 의한 학습기법에 의존하게 되었다.

실험을 통하여 추론모델을 학습시키고 그 성능을 평가해본 결과 NOx의 농도는 $\pm 5\%$ 이내의 오차로 진단이 가능하였으며, CO의 농도는 $\pm 20\%$ 이내에서 추론이 가능하였다. 신경회로망에 의한 학습 알고리듬은 정확하고 풍부한 실험 데이터가 확보된다면 CO의 농도도 정확한 모델링과 적은 오차내의 추론이 가능할 것으로 기대된다.

2. 이론적 배경

2.1 화염의 발광 메커니즘

화염의 발광을 발광원인 중심으로 분석하면, 연소과정의 각종 화학반응에 의해 발생하는 반응광(chemiluminescence)과 라디칼의 자발광(radical luminescence), 그리고, 미립자(soot)의 열적방사

Table 1 Wavelength of luminecense

Luminecense Source	Chemical Species	Wavelength
radical	OH	306.36nm, 306.7nm, 308.9nm, 312.2nm, 314.4nm
	CH	431.5nm, 438.4nm, 387-396nm, 314nm
	C2	563.6nm, 516.5nm, 460-498nm, 285.5-298.7nm
	NO2	600-875nm
soot	CO	430nm
	H2O	800-1250nm

(thermal radiation)의 세 가지로 분류할 수 있다. 반응광은 연료내의 화학물질들이 공기중의 산소, 질소, 혹은 연료내의 다른 화학물질들과 화학반응을 일으키면서 발생시키는 발광이다. 라디칼의 자발광은 연소 반응 중에 생성된 라디칼들이 안정화되면서 발생하는 자발광이다. 열적 방사는 화염장내에 존재하는 미연분이나 입자들이 고온 상태에서 발생하는 복사광이다. 탄화 수소계 연료의 경우, 위의 세 가지 발광이 모두 관측된다. 특히, 연료가 유류인 경우, 열적 방사가 우세해, 열적 방사와 같은 파장대의 라디칼의 자발광이나 반응광의 에너지는 계측되지 않는다. (신현동³⁾등이 연구한 바에 의하면, CH 라디칼의 자발광 파장과 CO의 발광파장이 거의 같기 때문에, 유류버너의 화염을 분광기를 사용하여 계측했을 때 관측되는 에너지는 CH 라디칼의 자발광 에너지가 아닌, CO의 발광 에너지이다.) 이상의 반응광들의 발광파장에 대해, Dean⁽⁵⁾은 광도측정(photometry)기법을 화염 관찰에 응용하여 여러 라디칼들의 발광 주파수를 계측하였다. 그리고, Stile⁽⁶⁾등은 Molecular Emission Cavity Detection (MECD)기법을 이용하여 라디칼과 각종 반응광의 주파수를 계측하였다. Table 1에서 광도 측정 기법과 MECD 기법으로 계측한 각 물질의 발광파장을 정리하였다.

2.2 화염해석을 위한 색모델(Color Model)

색모델⁽⁶⁾이란, 기본요소와 조합 규칙을 정의하고, 모든 색을 기본요소의 조합으로 표현하는 색표현 방식이다. 색모델을 쓰는 가장 큰 목적은 모든 색을 몇 개의 기준에 따라 정리하기 위해서이다. 본 연구에서는, 화염장 내에서 반응하는 여러 화학종들의 발광을 파장의 관점에서 해석하기

위해서 HSI 모델을 해석 모델로 선정하였다. HSI 모델⁽⁸⁾이란, Hue, Saturation, Intensity의 선형 조합으로 색을 표현하는 방식이다. Hue는 가장 지배적으로 강조되는 색(dominant color)으로서, 대상으로부터 복사되는 가시광중, 가장 강한 에너지를 갖는 파장을 의미한다. Saturation은 원색에 섞인 흰색의 양(ratio of mixed white to hue)으로, 가시광 주파수 영역 내에서의 주파수에 따른 에너지의 표준편차를 의미한다. Intensity는 밝고 어두운 정도(grey level)이며, 대상체의 총 복사에너지를 의미한다. 기하학적 측면에서, HSI 모델의 기초를 이루는 Hue, Saturation, Intensity는 원통좌표계의 각, 거리, 높이와 같으며, 좌표계 내의 한 점은 한 색을 대표한다. 식 (1)은 HSI 모델의 색 표현식이다.

$$C = H\hat{h} + S\hat{s} + I\hat{i} \quad (1)$$

식에서, C는 표현하고자 하는 색이다. \hat{h} , \hat{s} , \hat{i} 는 각각 hue, saturation, intensity의 단위벡터이고, H, S, I는 각각 색이 가지고 있는 hue, saturation, intensity의 값이다. 식 (2)에 RGB 모델로부터 HSI모델을 유도하는 공식을 나타내었다.

$$\begin{aligned} H &= \cos^{-1} \left\{ \frac{\frac{1}{2}[(R-G)+(R-B)]}{\sqrt{(R-G)^2+(R-B)(G-B)}} \right\} \\ S &= \frac{3}{(R+G+B)} \min[R, G, B] \\ I &= \frac{1}{3}(R+G+B) \end{aligned} \quad (2)$$

2.3 HSI 모델을 이용한 화염발광의 해석

Hue는 가장 큰 에너지를 가지는 파장(dominant wavelength)을 의미한다. 화염 발광 측면에서 Hue는 CCD 소자의 면적에 비례하는 화염의 면적에서 일어나는 발광 중, 가장 큰 에너지를 가지는 발광파장을 의미한다. CCD 카메라의 계측 가능한 최장 파장을 λ_{max} 라하고, 최단 파장을 λ_{min} 이라 하면, 화염 발광의 파장(λ)과 Hue 사이에는 변환 관계가 성립된다. 식 (3)과 (4)는 파장과 Hue 레벨 간의 상관관계식이다.

$$\lambda = -\frac{\lambda_{max} - \lambda_{min}}{\text{Quantization Level}} \text{Hue} + \lambda_{max} \quad (3)$$

$$\text{Hue} = \frac{\text{Quantization Level}}{\lambda_{max} - \lambda_{min}} (\lambda_{max} - \lambda) \quad (4)$$

위 식에서, Quantization 레벨은 영상획득장치

Table 2 measurable wave length with CCD Camera

Luminecense Source	Chemical Species	Hue level in accordance with wavelength
radical	OH	not measurable
	CH	229, 223
	C2	116, 157, 205-172
	NO ₂	0-85
soot	CO	230
	H ₂ O	not measurable

(Image Grabber)에 내장되어 있는 A/D 변환기의 분해능을 의미한다. 식에서 나타났듯이 Hue 레벨 값과 파장 λ 는 서로 변환 가능하지만, 그 정확한 대응은 카메라와 영상취득장치에 내장된 A/D 변환기의 사양에 따라 크게 좌우된다. Table 2는, Human Vision⁽⁸⁾이 정의하는 가시광의 파장대인 $\lambda_{\max} = 700 \text{ nm}$, $\lambda_{\min} = 400 \text{ nm}$ 로 놓고, A/D 변환기의 분해능을 일반적인 영상처리장치의 비디오 A/D 변환기의 분해능인 256으로 치환하였을 때, 발광원의 파장에 대응하는 Hue 값이다.

Intensity는 CCD 소자가 대상 물체로부터 측정할 수 있는 최대 에너지에 대한 실제 복사강도의 비를 의미한다. Intensity는 화염의 복사 에너지를 알 수 있는 변수가 된다. 식 (5)는 Intensity와 에너지 관계식이다.

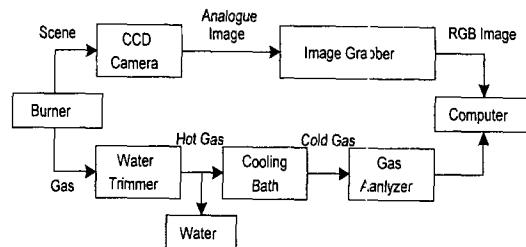
$$I = \frac{1}{a} \frac{E_s}{E_{\max}}, \quad E_s = E(T) \frac{3}{8} \left(\frac{d}{l} \right)^2 \frac{\cos \theta}{m} \quad (5)$$

위 식에서, E_s 는 CCD 활성소자에 복사된 에너지이고, E_{\max} 는 CCD소자의 최대 계측에너지이다. $E(T)$ 는 대상으로부터 방출되는 빛의 에너지이고, m 은 렌즈의 배율, θ 는 대상 점의 지향각, d 는 렌즈의 직경이고, l 은 렌즈로부터 물체까지의 거리, a 는 카메라 내부증폭기의 증폭비이다. Saturation의 정의는 Hue가 흰색에 의해 희석된 정도이다.

3. 실험방법 및 실험결과

3.1 실험장치

본 연구에 사용된 버너는 경유를 연료로 하는 오일버너이다. 실험에서는 선회를 최대값으로 고정한 상태에서, 연료 부하량을 최대분사량의 50%, 75%, 90% 상태에서 배출가스 중의 산소량

**Fig. 1** Structure of Measuring Apparatus

을 2~5%의 영역내에서 변화시켜가며 NO_x와 CO₂의 농도를 계측하고 영상을 취득하였다.

영상처리장치는 영상을 수집하는 카메라와, 카메라에서 전압신호로 변환된 영상신호를 컴퓨터에서 처리할 수 있는 디지털 신호로 변환해주는 영상획득장치로 구성되어 있다. 본 연구에서는, 파나소닉사의 WV-CL300 카메라와 레녹스(Lenox)사의 렌즈튜브(Lens Tube)를 장착한 벌(Burle)사의 TC270 카메라 및 Cosmica 카메라를 사용하였다. 벌의 측면에 구멍을 내어 렌즈튜브를 장착하여 화염영상을 취득하였다. 영상획득장치는 캐나다 코레코(Coreco)사의 Ultra II를 사용하였다. Ultra II는 카메라로부터 입력되는 YIQ모델의 아날로그 신호를 RGB 모델의 디지털신호로 변환하는 고속 비디오 A/D변환기와 2Mb의 메모리를 내장하고 있다.

본 연구에서 관심을 둔 배출가스는 NO_x와 CO의 농도, 배출가스중의 O₂량이다. NO_x계측 장비는 정엔지니어링사의 Auto Stack Measureeing System과 Rosemount Analytical Inc.의 Model 951A를 사용하였다. CO계측 장비는 Thermo Electronic Instrument사의 CO Analyzer를 사용하였고, O₂ 분석기는 일본 Cosmos사의 Cosmos O₂분석기와 Servomex사의 1420B를 사용하였다.

3.2 실험방법

본 연구에 사용된 버너는 배출가스의 온도를 제어변수로 하고, 연료 주입량 및 램퍼 개도를 조작변수로 하여 제어되도록 설계되어 있다.

실험방법은, 제어기에서 배출가스의 온도를 설정한 후, 배출가스의 실제 온도가 설정된 온도의 2% 이내에 수렴되었을 때 정상상태라고 판정하여 데이터를 획득하였다. 정해진 조건에서 일정

횟수만큼 화염의 영상을 취득하고 그와 동시에 배출가스 중의 각 성분별 가스 농도 및 산소량을 계측하여 컴퓨터에 저장하였다. 화염의 영상은 표준 TIFF 5.0 형식으로 저장하였고, 5장의 영상을 취득하여 평균한 값을 사용하였다. 가스농도와 산소량은 ASCII 형식으로 저장하였다. Fig. 1에 실현장치의 개요를 보였다. 배기ガス는 버너의 배기ガス출구에서 나오는 배기ガ스를 냉각시켜 수분을 제거한 후 가스분석기를 사용하여 성분을 분석하였다.

3.3 실험결과

영상수집장치를 이용하여 수집한 영상은 Fig. 2와 같다. 공연비가 변함에 따라 연소조건이 달라지고 화염의 밝기가 바뀌는 영상이다. 이때 측정한 배기ガス중에 포함된 NO_x의 농도가 화염의 밝기 및 색상에 따라 다르게 나타나고 있다.

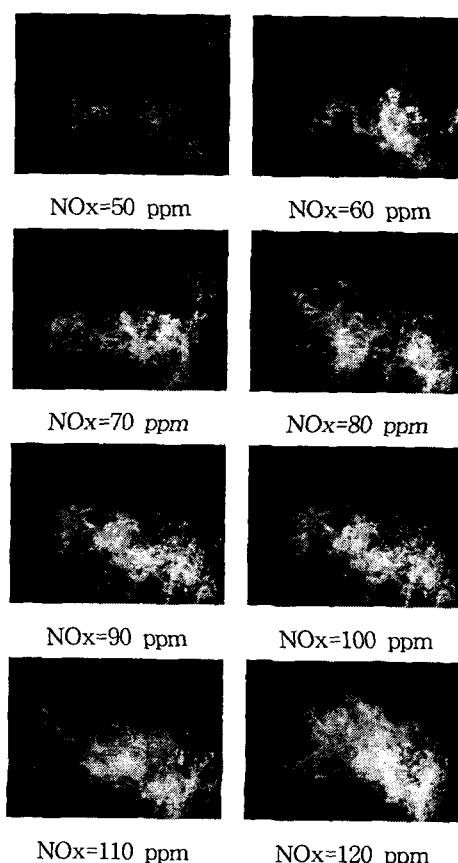


Fig. 2 Various flame image

화상의 변화에 따른 특징들을 추출해 내기 위해 한 장의 화염영상으로부터 Red, Green, Blue의 영상과 Hue, Saturation, Intensity영상을 분리했다. Fig. 3에서 각각의 영상에 대해 화소값의 분포를 구하였다. Red, Green, Blue, Hue, Saturation, Intensity의 6개 색상평면으로부터 화염의 상태진단에 필요한 파라미터들을 추출하였다. 이들 파라미터 중 배기ガス 중의 NO_x, CO 등의 농도와의 상관관계(cross correlation)를 구한 후, 가장 상관관계가 높은 파라미터들을 추출하였다. 이 파라미터는 유효화염의 면적과 Green Level의 화소평균값과 Blue Level의 화소값의 총합의 정보이다. 이 파라미터들은 뉴로퍼지 추론시스템의 입력변수로 사용되었다.

4. 뉴로퍼지 학습 알고리듬

4.1 뉴로퍼지 시스템

인공신경회로망(Artificial neural network)의 학습능력과 퍼지논리제어기(Fuzzy Logic Control)의 전문가 제어 능력을 결합한 것이 뉴로퍼지논리제어

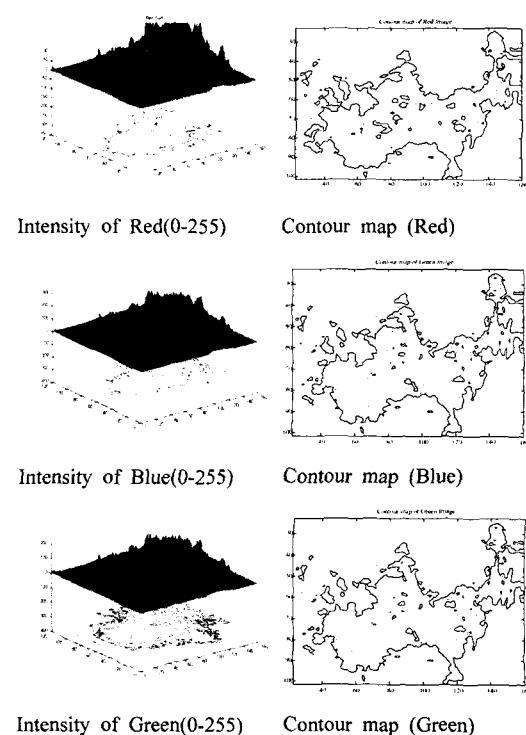


Fig. 3 Color map of flame image

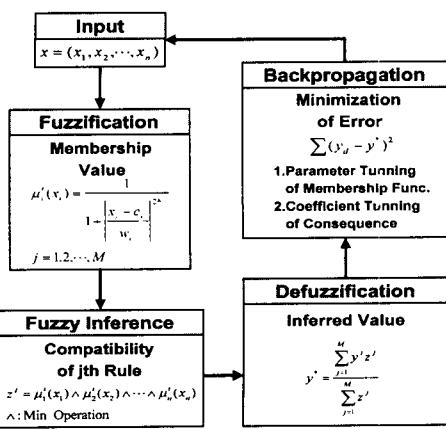


Fig. 4 Flowchart of Neuro-Learning algorithm

시스템(neuro-fuzzy logic control system)이다. 이러한 방식의 시스템은 철저하게 입·출력 데이터를 바탕으로 하는 퍼지논리제어 시스템을 구성하는데 논리적인 해결책을 제시해 준다. 본 논문에서는 역전파(back propagation) 알고리듬을 이용한 뉴로학습(neuro learning)을 통하여 퍼지 추론 시스템의 파라미터들을 결정하였다.

학습 및 추론에서 사용된 추론 방식은 Takagi-Sugeno 방식이다. 이렇게 결정된 파라미터들을 이용하여 배기ガ스 중의 NOx 농도와 CO 농도를 추론하기 위한 퍼지 추론 시스템을 구성한다.

4.2 역전파(back-propagation) 학습 알고리듬

본 논문에서 사용된 뉴로-학습 알고리듬은 오차 역전파 알고리듬으로서 우선 초기 언어정보를 통한 퍼지 추론 시스템의 설계를 통하여 개략적인 추론 시스템의 파라미터 값을 정하고 입·출력 데이터를 가지고 오차 역전파 알고리듬에 적용하여 퍼지 추론기의 파라미터를 조율한다.

퍼지 추론방법은 Takagi-Sugeno 방법을 사용하였으며 후건부 소속 함수를 입출력 선형관계식으로 표현하여 비퍼지화를 추론기에 포함시킨 형태이다. Fig. 4에서는 본 논문에서 사용된 뉴로-학습 알고리듬의 흐름도를 나타내고 있다. 제시된 학습 알고리듬을 적용하기 전에 소속 함수를 구성하는 계수들, 퍼지규칙 후건부에서 정의되는 선형 함수식의 계수들과 같은 초기 파라미터를 설정한다. 초기값으로 결정된 이 파라미터들은 다음의 학습 단계를 거치면서 조율된다.

첫 번째 단계로서, 학습시키고자 하는 입력 데이터(선정된 각각의 파라미터) $x = (x_1, x_2, \dots, x_n)$ 을 입력으로 하여 초기에 구성된 추론 시스템에 입력한다. 두 번째 단계로, 초기에 설정된 퍼지 규칙의 전건부를 이용하여 입력된 각각의 데이터에 대한 소속도(degree of membership)를 결정하게 된다. 본 논문에서는 일반화된 종 형상(bell shape)의 소속 함수를 사용하였으므로 i 번째 입력변수의 값 x_i 가 퍼지집합 A_i^j 에 대응되는 소속도 $\mu_i^j(x_i)$ 값은 다음과 같이 구해진다.

$$\mu_i^j(x_i) = \frac{1}{1 + \left| \frac{x_i - c_i^j}{w_i^j} \right|^{2b_i^j}} \quad (6)$$

세 번째 단계로, j 번째 퍼지규칙의 적합도 z^j 를 다음과 같이 Min 연산을 사용하여 계산하여 모든 규칙들에 대한 적합도를 구한다.

$$z^j = \mu_1^j(x_1) \wedge \mu_2^j(x_2) \wedge \dots \wedge \mu_n^j(x_n) \quad (7)$$

$$j = 1, 2, \dots, M$$

여기서 \wedge 는 Min 연산, M 은 퍼지규칙의 수를 나타낸다. 네 번째 단계에서는, 각 퍼지 규칙에 의해 세 번째 단계에서 계산된 적합도와 후건부 값을 결정된 출력값을 이용하여 최종 추론값 y^* 를 다음과 같이 계산한다.

$$y^* = \frac{\sum_{j=1}^M y^j z^j}{\sum_{j=1}^M z^j} \quad (8)$$

식 (8)로부터 구해진 y^* 는 퍼지 추론 시스템에서 비퍼지화한 수치 값에 해당한다.

마지막 단계로, 오차를 계산하여 그 오차값이 최소화가 되도록 역전파 알고리듬을 적용한다. 다층 신경회로망에 의한 적응 퍼지 제어기의 파라미터를 미세 조정하는 과정은 입력 데이터 x_1, x_2, \dots, x_n 에 대한 출력 y^* 를 계산하고 원하는 출력 y_d 와의 오차의 제곱의 합을 최소화하도록 역방향으로 소속 함수의 위치인 c_i^j 와 소속 함수의 폭인 w_i^j 및 후건부의 선형결합식의 계수인 $a_1^j, a_2^j, \dots, a_n^j$ 을 조정한다. 전체 오차값은 다음과 같이 정의된다. 여기서, L 은 학습 데이터 집합의 수를 나타낸다.

$$E = \sum_{m=1}^L (y_d - y^*)^2 \quad (9)$$

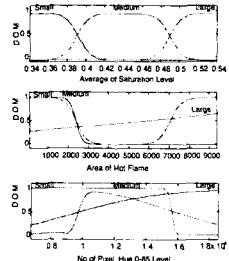


Fig. 5 3-Membership function of NOx

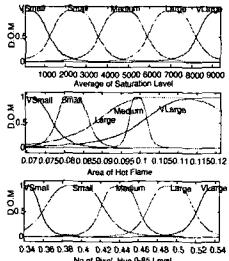


Fig. 6 5-Membership function of NOx

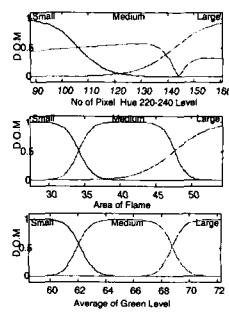


Fig. 7 3-Membership Function of CO

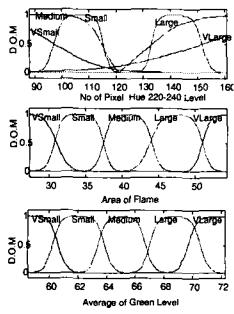


Fig. 8 5-Membership function of CO

만일 조정해야하는 파라미터가 q 라면 파라미터의 변화량은 다음과 같이 정의된다.

$$\Delta q = -\eta \frac{\partial E}{\partial q} \quad (10)$$

이때 η 는 학습률(learning rate)로서 식 (11)과 같이 정의되며, k 는 step size를 나타낸다.

$$\eta = \sqrt{\sum_p \left(\frac{\partial E}{\partial p} \right)^2} \quad (11)$$

4.3 퍼지추론 시스템

뉴로-학습을 통하여 결정된 소속 함수, 퍼지 규칙 및 후건부의 선형결합 함수를 이용하여 퍼지 추론 시스템을 구성하였다.

Fig. 5는 배기ガ스 중의 NOx 농도를 추론하기 위해 3개의 입력변수를 사용한 경우의 소속함수를 나타낸다. 입력변수는 다시 각각 3개의 퍼지 공간으로 분할되었다. Fig. 6은 배기ガ스 중의 NOx 농도를 추론하기 위하여 5개의 소속함수를 사용한 입력변수이며 3개의 입력변수들은 5개의 퍼지 공간으로 분할되었다.

Table 3은 3개의 소속함수를 사용하여 학습된

Table 3 Fuzzy rule base CO

No.	Warm Area	Average Green	Volume Blue	Parameters of Consequence			
				C_0^i	C_1^i	C_2^i	C_3^i
1	L	L	L	0.1464	-1280.1	-3307.2	1449.8
2	L	L	M	0.2028	5198.4	-2983.7	534.25
3	L	L	S	-0.778	1413.2	-1104.9	1820.1
4	L	M	L	0.0364	-211.71	210.70	-277.32
5	L	M	M	1.7679	-985.83	-554.67	-1912.2
6	L	M	S	-6.949	482.88	4101.6	7587.8
7	L	S	L	0.0035	372.57	431.89	-111.63
8	L	S	M	-0.287	-7070.5	-843.28	1362.9
9	L	S	S	0.8701	-2564.5	1606.7	-1076.7
10	M	L	L	0.3166	-1110.2	-1116.9	-593.47
11	M	L	M	-0.077	-6763.4	3178.9	-486.51
12	M	L	S	-0.027	-1600.3	708.54	71.766
13	M	M	L	-1.359	-9.4705	339.79	694.33
14	M	M	M	-2.091	-473.88	-244.89	559.91
15	M	M	S	9.8931	-369.39	-918.54	-2233.0
16	M	S	L	0.2547	876.18	-1372.2	178.68
17	M	S	M	-0.264	2328.4	643.94	733.66
18	M	S	S	1.0215	-117.51	-1497.9	-3583.2
19	S	L	L	2.5456	-97.491	176.40	497.87
20	S	L	M	-0.223	-3596.8	3509.8	23.456
21	S	L	S	-0.017	-340.09	2434.5	-1157.9
22	S	M	L	58.249	-1.2767	4.2653	6.3216
23	S	M	M	40.369	-18.011	-25.458	-45.347
24	S	M	S	-212.9	-4.5738	-0.2791	-5.9193
25	S	S	L	-5.483	20.146	-41.856	-55.179
26	S	S	M	0.3775	146.17	288.26	906.41
27	S	S	S	0.0575	-16.467	153.99	175.77

27개의 퍼지규칙을 나타내고 있다. 5개의 소속함수를 사용한 경우 125개의 퍼지규칙을 가진다.

Fig. 7과 Fig. 8은 각각 3개와 5개의 소속함수를 사용한 CO의 농도추론을 위한 소속함수이다.

Table 3은 배기ガ스중의 NOx농도를 추론하기 위한 규칙이며, 그 의미는 다음과 같다.

IF (Average of Saturation is Large) and (Hot Area is Large) and (Pixel Number of Hue Level 0-85 is Large) THEN NOx(ppm) = 0.1464 * (Average of Saturation) -1280.31 * (Hot Area) + 1449.85

이 규칙은 “화염영상의 Saturation Level 평균값이 크고 화염의 고온부 면적이 크고 Hue Level의 화소값이 0-85사이인 픽셀 수가 많으면 첫째 규칙에 대한 출력을 후건부에 주어진 식으로 하라”를 의미한다.

전건부의 언어적 표현으로부터 각각의 입력에 대한 소속도는 식 (1)을 이용하여 구하고 구해진

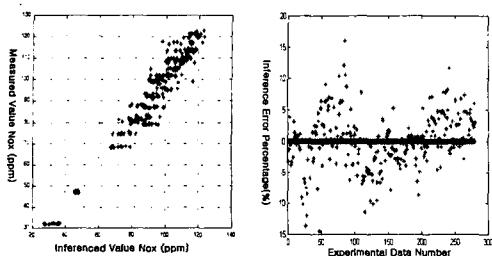


Fig. 9 Inference results and error of NOx
(3 Membership functions)

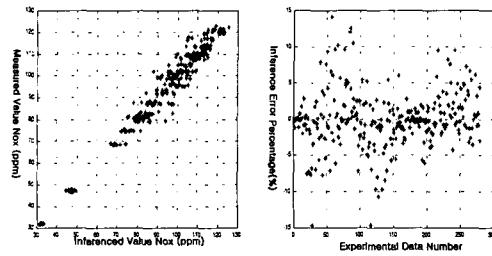


Fig. 10 Inference results and error of NOx
(5 Membership functions)

네 개의 소속도로부터 Min 연산자를 이용하여 첫 번째 퍼지규칙의 적합도를 계산한다.

후건부의 선형 결합식으로부터 각각의 입력값을 대입하여 첫 번째 퍼지규칙에 대한 출력값을 계산한다. 한 장의 화염영상을 통한 입력값에 대해 위의 방법으로 모든 퍼지규칙에 적용하여 각각의 적합도와 후건부의 출력값을 계산하고 최종 출력값은 식 (3)으로 구한다.

5. 추론결과

구성된 퍼지 추론 시스템을 이용하여 베너의 연소상태를 진단하고자 하였다. 우선 화염영상으로부터 배기ガス중의 NOx 농도와 CO농도를 추론하였다. Fig. 9는 배기ガス 중의 NOx 농도에 대한 추론 오차를 실제 실험에서 측정한 NOx의 농도에 대해 그래프로 나타낸 것이다. 추론 오차는 실험에 의해 측정된 배기ガ스중의 NOx 농도와 퍼지추론에 의한 NOx 농도 추론값의 차를 측정된 NOx 농도에 대한 백분율의 비로 정의된다.

Fig. 10은 배기ガス 중의 NOx 농도를 추론하기 위하여 5개의 소속함수를 사용하여 학습한 추론 모델로 추론한 결과이다. 3개의 소속함수를 사용하였을 때와 같은 경향의 추론결과를 나타낸다.

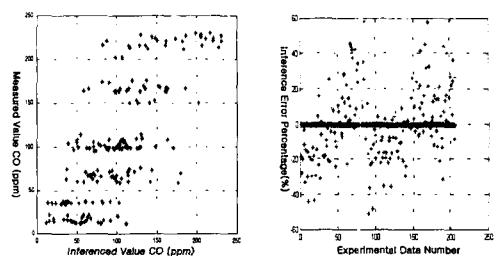


Fig. 11 Inference results and error of CO
(3 Membership functions)

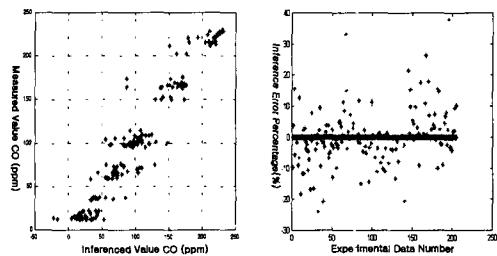


Fig. 12 Inference results and error of CO
(5 Membership functions)

CO의 추론을 위한 소속함수는 특정 Hue 화소레벨을 가지는 픽셀의 개수, 유효화염면적, Greer level의 평균값이 사용되었다.

그러나 5개의 소속함수를 사용한 경우 125개의 추론규칙을 가지므로 추론에 소요되는 연산시간이 길다는 단점이 있다. 본 논문에서는 125개의 추론규칙을 생략하였다.

Fig. 11은 3개의 소속함수로서 배기ガス중의 CO 농도를 추론한 결과이다. 추론결과에서 알 수 있듯이 추론오차가 크다. Fig. 12는 5개의 소속함수로서 배기ガ스 중의 CO 농도를 추론한 결과이다. CO의 경우 3개의 소속함수만으로는 추론 시스템을 구성하기 어렵고 5개의 소속함수에 의해 125개의 추론규칙을 사용했을 때 작은 오차범위 내에서 추론이 가능하다.

배기ガス에 포함되어 있는 검은색 입자의 형태를 가지는 분진(Soot)의 농도를 추론하기 위한 시도를 하였으나 만족할 만한 추론결과를 나타내주는 추론시스템을 구성하지 못하였다.

그러나 분진의 농도를 정확히 측정하고 이들과 화염의 영상과 연소상태와의 상관관계를 정확하게 찾을 수 있다면 더욱 정확하고 신뢰성 있는 연소상태진단 시스템을 구성할 수 있을 것으로

기대된다.

6. 결 론

화염의 색상을 이용하여 연소상태를 진단하고자 영상처리기술을 이용하였다. CCD 카메라와 영상획득장치를 통하여 얻은 화염영상을 이용하여 화염의 연소상태를 진단할 수 있는 가능성을 확인하였다.

배기ガ스 중의 화염영상에서 얻은 유효화염의 면적과 Green Level의 화소평균값과 Blue Level의 화소값의 총합의 정보로부터 배기ガ스 중의 NO_x의 농도와 CO의 농도를 추론할 수 있었다.

다양한 입력변수들의 상관관계를 선형적으로 구하기 힘든 복잡한 관계의 추론시스템 구성에 적합한 뉴로퍼지에 의한 학습 알고리듬은 화염의 화상정보로부터 얻은 다양한 파라미터들로부터 배기ガ스 중의 NO_x 및 CO농도를 추론하는 퍼지 추론시스템을 구성하는 방법으로 적절하게 사용할 수 있었다.

이상의 실험에서 얻은 분석결과는 벤치버너의 화염영상과 배기ガ스 중의 NO_x와 CO 농도의 상관관계를 찾을 수 있는 가능성을 보여주고 있다.

향후 벤치규모의 버너뿐만 아니라 다양한 종류의 버너에서 실시간 연소진단 및 버너의 연소상태제어 시스템 구축의 가능성이 기대된다.

후 기

본 논문은 1998년도 통상산업부 공업기반기술개발사업(주관기관 : (주)삼성중공업) 연구비에 의해 연구되었습니다.

참고문헌

- (1) Mitsunobu Hosino, Kynya Misno, Toshinori Toma, Yasuhiko Sato, Tamakato Yamanaka, "Combustion Monitoring System Applied Image Data Processing," 火力原子力發電 Vo1. 42. No. 12. pp. 1725~1733.
- (2) 이태원, 이선봉, 하종률, 1996, "디젤엔진에서 이색법을 이용한 화염온도와 Soot의 계측기술에 관한 연구," 대한기계학회논문집(B) 제 20권 제 9호, pp. 3007~3014.
- (3) 신현동, 1995, "연소진단을 위한 화상 취득방법과 화상처리기술에 관한 연구," 한국과학기술원 논문집.
- (4) 김성환, "화상처리를 이용한 버너의 연소상태 진단알고리듬," 경북대학교 석사학위논문, 1998.
- (5) John A. Dean, 1960, "Flame photometry," MaGraw-Hill.
- (6) David A. Stiles, A.C. Calokerinos, Alan TownShend, 1994, "Flame Chemiluminescence Analysis by Molecular Emission Cavity Detection," New York : Willey.
- (7) William K. Pratt, 1991, "Digital Image Processing," 2nd Ed, JOHN WILY & SONS, INC.
- (8) Ditchbrun, R.W. 1991, "Light," New York Publications.
- (9) Louis J. Galbiati, Jr. 1990, "Machine Vision and Digital Image Processing Fundamentals," Prentice-Hall International.
- (10) Emmanuel C. Ifeatchor, Barrie, 1996, "Digital Signal Processing A Practical Approach," Addison-Wesley Publishers.
- (11) 이태영, 김성환, 이상룡, 1999, "영상처리를 이용한 버너의 연소상태 진단," 한국정밀공학회지.