

A Design of GA-based Fuzzy Controller and Truck Backer-Upper Control

郭根昌* · 金周植** · 鄭秀鉉***

(Keun-Chang Kwak · Ju-Sik Kim · Su-Hyun Jeong)

Abstract - In this paper, we construct a hybrid intelligent controller based on a fusion scheme of GA(Genetic Algorithm) and FCM(Fuzzy C-Means) clustering-based ANFIS(Adaptive Neuro-Fuzzy Inference System). In the structure identification, a set of fuzzy rules are generated for a given criterion by FCM clustering algorithm. In the parameter identification, premise parameters are optimally searched by adaptive GA. On the other hand, consequent parameters are estimated by RLSE(Recursive Least Square Estimate) to reduce the search space. Finally, we applied the proposed method to the truck backer-upper control and obtained a better performance than previous works.

Key Words : GA, FCM, ANFIS, fuzzy controller, truck backer-upper control

1. 서 론

제어 시스템의 설계에서 가장 중요한 것은 제어대상의 입력 특성을 방정식으로 표현하는 수학적 모델을 구하는 것인데, 대부분의 경우 제어대상은 복잡하고 예측하기 어려운 요소가 많이 포함되어 있으므로 모델링은 매우 어려운 문제이다. 따라서 실제 시스템에 대해 정확한 수학적 모델링을 할 수 있는 경우는 거의 없고, 선형적으로 근사화하여 적절한 모델을 얻었다 하더라도 실제 제어대상과 모델사이에는 항상 모델링 오차가 존재하게 되므로 설계된 제어기가 실제 환경에서도 좋은 결과를 낸다는 보장이 없다. 따라서 비선형성을 많이 포함하고 시간에 따라 특성이 변화하는 실제 시스템에 대해서는 미리 결정된 제어법칙으로는 제한된 성능밖에 기대할 수 없으므로 수학적 모델링이 필요하지 않고, 동작조건 변화에 대처할 수 있는 적응적인 제어방식이 필요하다.

기존의 Mamdani[1] 형태의 퍼지 제어기법은 주관적인 불확실성을 수학적으로 표현할 수 있도록 해주는 퍼지 집합이론에 근거해서 제어대상의 수학적 모델을 구하지 않고 전문가의 경험이나 공학적인 상식을 가지고 효과적으로 제어를 할 수 있게 해 주는 특징을 가지고 있다. 그러나 전문가의 경험이나 공학적인 상식에 의해서 제어규칙을 생성할 수 있는 경우가 존재하지만, 이와 같은 지식을 미리 가지고 있지 않은 경우에는 퍼지 제어규칙을 자동적으로 생성하는 방법이 필요하게 된다. 이런 이유로 수치적인 입력력 데이터로부터 자동적인 퍼지규칙을 생성하기 위해 많은 연구들이 진행되고

있다. 대부분의 이러한 연구들은 퍼지 시스템과 신경회로망의 융합인 뉴로-퍼지 시스템을 기초로 하고 있다[2-4]. 대표적으로 Jang[5]의 ANFIS는 복잡한 비선형 시스템에 대해서 적은 규칙으로 개선된 성능을 보이며, 여러 응용분야에서 적용되고 있다[6,7]. 그러나 ANFIS는 그리드 분할로 인해 입력공간의 수가 증가함에 따라 규칙의 수가 지수적으로 증가한다는 문제점을 가지고 있다. 또한 전제부 및 결론부 파라미터를 학습할 때, LSE(Least Square Estimate)와 BP(Back-Propagation)을 이용한 하이브리드 학습을 수행하지만, BP 알고리즘은 전역적인 해가 아닌 국소적인 최소점에 빠질 수 있는 문제점을 가질 수 있다.

본 논문에서는 위의 문제점들의 개선과 자동적인 퍼지규칙의 생성을 위해서 Bezdek[8]에 의해 제안된 적응적인 스캐터 분할에 근거한 FCM 클러스터링을 이용하여 TSK(Takagi-Sugeno-Kang) 형태의 if-then 규칙을 생성하고, ANFIS[5]의 구조동정을 수행하도록 하였다[9]. 초기 구축된 시스템은 GA와 RLSE에 의한 하이브리드 GA를 이용하여 전제부 및 결론부 파라미터가 최적화 되도록 하였으며, GA는 SGA(Simple Genetic Algorithm)을 변형시킨 AGA(Adaptive Genetic Algorithm)[11]를 적용하였다. 제안된 방법은 적합도의 값에 의해서 적응적으로 교배확률 및 돌연변이확률을 변화시켜 집단 다양성 유지와 전역적인 해의 수렴속도를 가속화하고, 엘리티즘을 이용하여 수렴성을 보장하게 하였다. 그리고 트럭 후진제어[12-15]에 제안된 방법을 적용하였고, 기존의 방식과 비교하여 개선된 성능과 유용성을 검증하였다.

2. 유전 알고리즘(Genetic Algorithm ; GA)

GA는 자연세계의 진화과정을 컴퓨터 상에서 시뮬레이션함으로써 복잡한 실세계의 문제를 해결하고자 하는 계산 모델로서 자연선택의 원리와 자연계의 생물학적 기본이론에 근거

* 正 會 員 : 忠北大 電氣工學科 工博

** 正 會 員 : 忠北大 電氣電子및컴퓨터工學部 專講·工博

***正 會 員 : 大元科學大學 電氣科 副教授·工博

接受日字 : 2002年 2月 27日

最終完了 : 2002年 5月 28日

한 병렬적이고, 전역적인 탐색 알고리즘이다. GA의 특징을 살펴보면 첫째, 파라미터 자체가 아니라 파라미터들의 부호화된 정보를 다루기 때문에 파라미터의 연속성이나 미분가능성의 제약을 받지 않는다. 둘째, 전통적인 최적화 방법에서는 점에 서 점으로 움직이는 방법들이 적용되었는데 GA는 단일 점이 아닌 여러 점들의 집단에서 탐색을 하여 전역적인 해의 발견을 가능하게 한다. 셋째, 미분값이나 다른 보조정보를 이용하지 않고 적합도함수의 정보만을 이용한다. 이런 장점으로 인해 GA는 최적화 문제, 인공지능, 시스템 분석 및 예측, 제어 및 로보틱스 등 여러 산업 및 경제분야에 적용되고 있다.

GA의 개체 표현법은 문제에 대한 해를 염색체로 표현하며, 염색체의 표현방법에 따라 정수값, 이진 스트링, 실수 스트링, 트리, 그래프 등이 있다. 본 논문에서는 문제의 변수값을 이진 스트링으로 표현한다. 좀 더 구체적으로 문제의 한 변수에 대한 최소값과 최대값을 알고 이 변수의 값을 n 개의 비트로 최적화하고자 할 때, 식 (1)과 같은 디코딩 방식에 의해 각 이진 스트링에 대한 실수값을 구할 수 있다.

$$\text{var}_{\text{bin}} \frac{(\max - \min)}{2^n - 1} + \min \quad (1)$$

여기서, var_{bin} 은 이진 스트링에 대한 십진수의 값이고, n 은 이 변수에 배정된 스트링의 길이이다.

GA의 연산자로는 복제, 교배, 돌연변이로 구성되고, 각 연산자에 대해 간략하게 설명하면 다음과 같다. 복제는 각각의 스트링이 가지는 적합도에 따라 스트링을 복제하는 과정이며, 이때 적합도함수는 사용자가 최대화하기를 원하는 어떠한 형태의 함수도 가능하다. 이 과정은 적합도가 높은 개체일수록 다음 세대에 더 많은 자손을 가질 확률이 높음을 의미하며, 주어진 환경에 더 잘 적응하는 개체들은 살아남고 잘 적응하지 못한 해들은 도태되도록 유도함으로서 자연 선택현상을 모델링한다. 보통 이진 스트링을 사용하는 GA에서는 적합도에 비례하여 다음 세대의 복제가 진행되는 데 이를 적합도 비례선택이라 한다. 이를 구현하기 위해서는 주로 룰렛 휠 (roulette wheel) 선택법이 이용된다. 본 논문에서는 최상위의 두 개체는 항상 다음세대에 유전자를 전달하고 최하위의 개체는 도태되는 엘리트(elite) 선택법을 이용하였으며, 나머지 개체에 대해서는 룰렛 휠 선택법을 사용하였다.

복제과정은 탐색방향을 적합도가 가장 높은 개체쪽으로 향하게 하지만 새로운 개체를 생성하지는 못한다. 다른 구조를 갖는 개체들을 탐구하기 위한 연산자로서 교배 연산자가 사용된다. 교배는 세 단계로 수행되며, 먼저 선택 연산자에 의해 개체군에서 두 개의 부모개체가 선택된다. 다음으로 이들이 염색체 교환을 일으키기 위한 교배위치가 임의로 결정된다. 마지막으로 교배위치를 기준으로 두 염색체간에 유전자 값이 교환되어 새로운 두 개의 자식개체가 생성된다. 교배는 교배확률 P_c 에 의해 그 적용빈도수가 제어되며, 본 논문에서는 식 (2)와 같이 적합도의 값에 따라 적응적으로 변하는 일점교배를 사용하였다.

$$\begin{aligned} P_c &= k_1(f_{\max} - f') / (f_{\max} - \bar{f}), \quad f' \geq \bar{f} \\ P_c &= k_3, \quad f' < \bar{f} \quad k_1, k_3 \leq 1.0 \end{aligned} \quad (2)$$

여기서, f_{\max} 는 집단의 최대 적합도, f' 는 교차되는 개체들 중의 큰 적합도이며, \bar{f} 는 집단의 평균 적합도이다.

돌연변이 연산자는 개체군의 다양성을 유지하는데 중요한 역할을 수행한다. 또한 교배만에 의해서는 이 위치에 새로운 유전형질을 부여할 수 없으나 돌연변이 연산자는 이것이 가능하도록 해준다. 본 논문에서는 돌연변이확률 P_m 을 적합도에 따라 식 (3)과 같이 적응적으로 변화하도록 하였다.

$$\begin{aligned} P_m &= k_2(f_{\max} - f) / (f_{\max} - \bar{f}), \quad f \geq \bar{f} \\ P_m &= k_4, \quad f < \bar{f} \quad k_2, k_4 \leq 1.0 \end{aligned} \quad (3)$$

GA에서 사용되는 적합함수(fitness function)는 각 개체의 적합도를 평가하는 기반으로서 최적화하고자 하는 함수이다. 보통 적합함수의 변위는 문제마다 다르기 때문에 보통 정해진 구간 사이의 양수의 값을 갖도록 표준화된 값을 사용하며, 본 논문에서는 다음 관계식을 사용하였다.

$$f = F - \min(F) \quad (4)$$

여기서, F 는 표준화 이전의 적합함수를 나타내고, f 는 표준화된 적합함수의 값을 나타낸다. 적합함수는 퍼지모델의 출력과 원하는 출력사이의 평균제곱오차에 대한 역수를 사용한다. 그리고 수치적인 입출력 데이터를 학습 데이터와 검증 데이터로 나누어 각각 모델 형성과 모델 검증에 사용하기 때문에 식 (5)와 같은 적합함수 형태를 사용한다.

$$F = \frac{1}{1 + MSE_{\text{trn}} + MSE_{\text{chk}}} \quad (5)$$

여기서, MSE_{trn} 과 MSE_{chk} 는 각각 학습 데이터와 검증 데이터에 대한 평균제곱오차이다. 이 적합함수는 학습 데이터에 대한 근사화 능력과 검증 데이터의 일반화 능력을 모두 가지고 있기 때문에 학습 데이터와 검증 데이터에 대한 오차를 함께 줄일 수 있다.

3. GA 기반 퍼지 제어기

본 장에서는 GA와 FCM 클러스터링을 이용한 퍼지 시스템을 구축하기 위해 구조동정과 파라미터 동정이 수행된다. 구조동정은 FCM-ANFIS를 이용하여 초기 퍼지 시스템을 구축하며, 구축된 시스템을 이용한 파라미터 동정은 GA와 RLSE에 의해 전제부 및 결론부 파라미터가 최적화된다. 구조동정에 사용된 FCM 클러스터링을 살펴보면 다음과 같다.

Bezdek[8]에 의해 제안된 FCM 클러스터링은 식 (6)과 같은 목적함수를 최소화하도록 하는 반복적인 알고리즘으로서 주어진 데이터로부터 유사한 클러스터를 나누며, 생성된 클러스터는 시스템의 특성적인 동작을 기술하는 규칙으로서 사용된다.

$$J(U, c_1, \dots, c_c) = \sum_{i=1}^c J_i = \sum_{i=1}^c \sum_{j=1}^n u_{ij}^m \|x_j - c_i\|^2 \quad (6)$$

여기서, c_i 는 퍼지그룹 i 의 클러스터 중심이고, m 은 가중치 지수로 일반적으로 $m=2$ 이다. 또한 u_{ij} 는 0과 1사이의 소속도 값이며, 식 (7)과 같이 데이터 집합에 대한 소속도의 합이 항상 1이어야 한다.

$$\sum_{i=1}^c u_{ij} = 1, \quad \forall j = 1, \dots, n \quad (7)$$

FCM 클러스터링 알고리즘의 클러스터 중심을 찾는 순서는 다음과 같다.

- [단계 1] $m(1 < m < \infty)$ 과 클러스터 수 $c(2 \leq c \leq n)$ 를 설정한다.
- [단계 2] 초기 분할행렬 $U^{(0)}$ 와 역치 ε 을 설정하고, 반복 지수는 0에서 p 까지 정한다.
여기서, $U[u_{ij}]_{i=1 \dots c, j=1 \dots n}$
- [단계 3] $U^{(p)}$ 와 다음 식 (8)을 이용하여 각각의 클러스터 중심 $c_i^{(p)}(i=1, 2, \dots, c)$ 를 계산한다.

$$c_i = \frac{\sum_{j=1}^n u_{ij}^m x_j}{\sum_{j=1}^n u_{ij}^m} \quad (8)$$

- [단계 4] $c^{(p)}$ 와 다음 식 (9)를 이용하여 다음 번 분할행렬 $U^{(p+1)}$ 을 구한다.

$$u_{ij} = \frac{1}{\sum_{k=1}^c \left(\frac{d_{ij}}{d_{kj}} \right)^{2/(m-1)}} \quad (9)$$

- [단계 5] $|J^{(p)} - J^{(p+1)}| \leq \varepsilon$ 이 만족한다면 멈추고, 그렇지 않으면 [단계3]로 가서 $p = p+1$ 로 설정한다.

FCM 클러스터링에 의해 스캐터 분할하여 적은 규칙의 수를 생성하도록 초기 퍼지시스템(FCM-ANFIS)을 구축한다. FCM 클러스터링에 의해 얻어진 각 클러스터는 가우시안 소속함수의 중심이 된다. 따라서 각 클러스터는 시스템의 특성을 기술하는 퍼지규칙으로 되며, 다음과 같이 TSK 형태의 퍼지규칙이 사용된다.

$$R^i = \text{If } x_1 \text{ is } A_1^i \text{ and } x_2 \text{ is } A_2^i \text{ and } \dots \text{ then } y^*_i = a_0^i + a_1^i x_1 + \dots + a_m^i x_m \quad (10)$$

여기서, $\{a_0^i, a_1^i, \dots, a_m^i\}$ 는 결론부 파라미터이고, 전제부의 가우시안 소속함수가 정해지면 RLSE에 의해 추정된다. 또한 퍼지 모델의 추론 값 y^* 는 가중평균법에 의해서 구해진다.

위와 같이 초기 FCM-ANFIS을 구축한 후에 GA와 RLSE에 의해 파라미터 동정을 수행한다. 여기서 사용된 GA는 적합도의 값에 근거해서 교배확률과 돌연변이확률을 적응적으로

로 변화시켜 집단의 다양성 유지와 전역적인 최적해의 수렴 속도를 가속화 할 수 있다. 이때 초기 구축된 FCM-ANFIS의 전제부 파라미터인 가우시안 소속함수의 중심과 폭을 초기 집단으로 발생시켜 GA에 의해 최적에 가깝도록 탐색된다. 결론부 파라미터는 선형방정식을 이루기 때문에 전제부 파라미터가 결정된 후에 RLSE에 의해 추정된다. 기존의 방식에서는 전제부와 결론부 파라미터를 모두 염색체로 표현함으로써 많은 탐색공간을 필요로 하지만, 제안된 파라미터 동정방법은 GA의 탐색공간이 줄어들어 빨리 최적에 가깝도록 원하는 해를 찾아낼 수 있다. GA에 의해 퍼지시스템이 구축되는 수행순서는 다음과 같고, 그림 1은 계층적인 표현을 나타내고 있다.

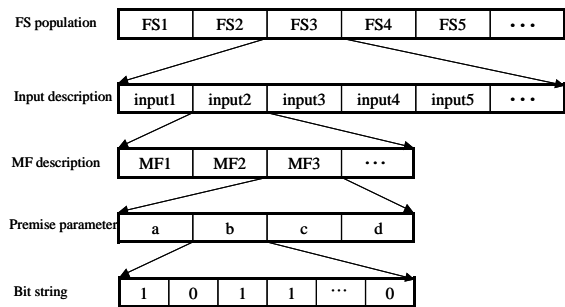


그림 1 GA에서 퍼지시스템의 계층적인 표현
Fig. 1 Hierarchical representation of fuzzy system in GA

- [단계 1] 세대수, 집단수, 교배확률, 돌연변이확률, 비트 수, 범위설정, 적합함수를 문제 고유의 특성에 알맞게 선택한다.
- [단계 2] 초기 FCM-ANFIS에서 얻어진 전제부 파라미터를 초기 집단으로 발생시킨다. 이때 결론부 파라미터는 RLSE에 의해 추정되며 가중평균법에 의해 퍼지모델의 출력값인 y^* 을 계산한다.
- [단계 3] 각 개체에 대한 적합함수 F 를 식 (5)와 같이 계산한다. 이는 학습 데이터와 출력 데이터에 대하여 퍼지모델의 출력과 실제 출력값 사이의 MSE에 대한 역수로 나타내어진다. 이 적합함수는 학습 데이터에 편중되지 않고 새로운 데이터에 대해서도 타당한 결과를 내는 모델인가를 평가할 수 있다.
- [단계 4] GA 탐색결과 수렴성을 보장하는 방법으로 엘리티즘 선택법을 이용하여 최상위의 두 개체를 선택하여 새로운 집단에 유지시킨다.
- [단계 5] 적합도의 값이 양의 값을 유지하도록 식 (4)와 같이 스케일링을 한다.
- [단계 6] 선택된 부모개체로부터 교배연산을 수행한다. 이때 교배확률은 식 (2)와 같이 적합도의 값에 따라 적응적으로 변한다. 여기서, k_1 과 k_3 는 각각 0.5와 1을 선택한다.
- [단계 7] 돌연변이는 엘리티즘 선택법에 의해 선택된 두 개체에는 영향을 주지 않도록 수행한다. 돌연변이확률도 적응적으로 변화하도록 식 (3)과 같이 계산된다. 여기서, k_2 와 k_4 는 각각 0.5와 1을 선택한다.

[단계 8] 설정한 세대수에 도달하거나 스케일링된 값의 합이 0이 되면 하나의 값에 수렴하기 때문에 종료한다. 만약에 그렇지 않을 경우에는 [단계 3]으로 가서 반복 수행한다.

4. 트럭 후진제어 및 시뮬레이션 결과

본 논문에서 다루고자 하는 트럭 후진제어는 비선형 문제로서 신경회로망이나 퍼지 시스템과 같은 지능시스템을 이용하여 성공적으로 제어할 수 있는 대표적인 예라고 할 수 있다. Nguyen와 Widrow[12]는 다층신경회로망으로 이루어져 있는 제어기와 에블레이터 네트워크를 가지고 트럭후진 제어 문제를 해결할 수 있다는 것을 보여주었다. 제어기 네트워크는 트럭의 현재 위치에 대해 원하는 조향각을 출력하고, 이와 직렬로 연결되어 있는 에블레이터 네트워크는 제어기 네트워크로부터 조향각이 주어지면 이를 이용하여 트럭을 일정한 거리만큼 후진시키는 역할을 한다. 그러나 이러한 신경회로망을 이용한 방법의 경우 충분히 학습되지 않았을 경우에 종종 극단적인 수렴특성을 보여주어 성공적이지 못한 궤적을 만든다. Kong과 Kosko[13]은 전형적인 퍼지 추론시스템을 이용하여 이 문제를 해결할 수 있다는 것을 보여 주었다. 그러나 여기서 사용된 퍼지시스템은 입력공간을 그리드 분할함으로써 많은 규칙이 생성되며, 전문가의 경험이나 공학적인 상식에 의한 지식을 미리 가지고 있지 않은 경우에는 퍼지 규칙의 생성이 어려운 단점이 있다. Wang[14]은 수치적인 입출력 데이터와 언어적인 규칙을 동시에 사용하여 규칙생성을 제안하였다. 그러나 Kosko방법과 마찬가지로 그리드 분할방법으로 인해 많은 규칙이 생성되는 문제를 안고 있다.

이러한 문제점을 해결하기 위해 본 논문에서 제안된 GA 기반 퍼지 제어기의 구조는 그림 2와 같다. 이 구조는 두 개의 입력을 가지고 있으며, 마지막 층에는 추론된 조향각을 일정한 범위 안에서 동작하도록 설정한다. 그림 3은 기존의 ANFIS와 제안된 FCM-ANFIS의 입력공간 분할 형태를 나타내고 있다. 그림에서 알 수 있듯이 입력공간이 증가할 때 제안된 스캐터 분할방법이 효과적임을 보여주고 있다.

트럭후진 제어문제는 한정된 주차공간에서 임의의 위치에서 원하는 주차위치에 후진하여 주차시키는 것을 목표로 하고 있다. 시뮬레이션에 사용된 트럭의 다이어그램과 주차영역은 그림 4와 같이 주어지고, 근사화된 트럭의 모델 운동식은 다음과 같다[13].

$$\begin{aligned} x(k+1) &= x(k) + v \cdot t \cdot \cos[\psi(k)] \\ y(k+1) &= y(k) + v \cdot t \cdot \sin[\psi(k)] \\ \psi(k+1) &= \psi(k) + v \cdot t/l \cdot \tan[\theta(k)] \end{aligned} \quad (11)$$

여기서, 속도 v 와 시간스텝은 각각 $-5 [m/s]$ 와 $0.5 [sec]$ 이며, 트럭길이 l 은 $4 [m]$ 로 가정하고, 각 변수의 범위는 다음과 같다.

$$-40 \leq x \leq 40, 0 \leq y \leq 50, -90 \leq \psi \leq 270, -45 \leq \theta \leq 45$$

입력변수는 x 축 좌표의 거리와 수평축에 대한 트럭 각 ψ 이

며, 출력변수는 조향각 θ 이다. 트럭과 주차위치 사이의 충분한 거리유지를 가정해서 y 축의 거리는 무시하였다[13-15].

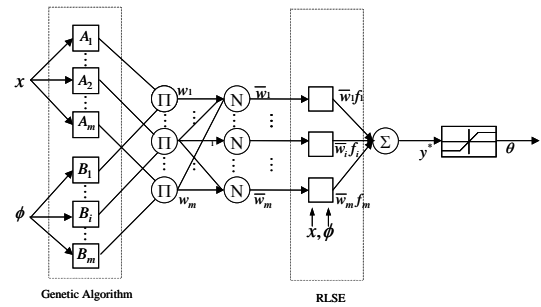


그림 2 GA 기반 퍼지 제어기의 구조
Fig. 2 Architecture of GA-based Fuzzy Controller




그림 3 ANFIS와 FCM-ANFIS의 입력공간분할
Fig. 3 Input Space Partition of ANFIS and FCM-ANFIS




그림 4 트럭의 다이어그램과 주차공간
Fig. 4 Truck diagram and parking space

제안된 GA 기반 퍼지 제어기에서 사용되는 입출력 데이터는 학습 데이터에 편중되지 않고 새로운 데이터에 대해서도 타당한 결과를 내는 모델인가를 평가하기 위해 그림 5와 같이 700개 데이터를 모델형성의 학습 데이터로 사용하였고, 나머지 700개의 데이터를 모델검증에 검증 데이터로 나누어 사용하였다. 입출력 데이터는 14개의 서로 다른 초기 위치와 다양한 각으로부터 입출력 데이터를 공학적인 상식에 근거로 해서 초기치 상태에서 시작한 때 단계마다 조향각 θ 를 결정하고, 여러 번의 시행착오 후에 성공적인 궤적에 대응되는 원하는 입출력 데이터 쌍을 선택하였다[13].

초기 FCM-ANFIS의 타당한 퍼지규칙의 수를 결정하기 위해 그림 6과 같이 규칙을 증가하면서 학습오차와 검증오차를 구하였다. 이 그림으로부터 학습오차는 규칙의 수가 증가함에 따라 오차가 작아지는 반면 검증오차는 7개의 퍼지규칙에서부터 점점 커지는 것을 알 수 있다. 따라서 초기 FCM-

ANFIS는 7개의 퍼지 규칙을 생성한다. 임의의 위치에서 원하는 주차위치에 최적의 궤적을 보이며 후진하여 주차를 하기 위해 제안된 방법을 적용하여 최적화를 수행하였다. 구축된 초기 퍼지 제어기의 전제부 및 결론부 파라미터를 초기치로 하여 다음의 제어 파라미터를 가지고 GA를 적용하였다.

세대 100, 초기 교배확률 0.95,
초기 돌연변이확률 0.01, 집단 30, 비트 16

그림 7은 GA 기반 퍼지 제어기에 의해 수행된 트럭의 궤적을 나타내고 있다. 이 그림으로부터 이상적인 궤적을 따라 정확하게 주차하고 있음을 알 수 있다. 그림 8은 세대에 따른 학습오차와 검증오차를 보여주고 있다. 학습오차와 검증오차가 함께 작은 평균제곱오차를 보이면서 수렴하고 있음을 알 수 있다.




그림 5 학습과 검증데이터의 분포
Fig. 5 Distribution of training and checking data

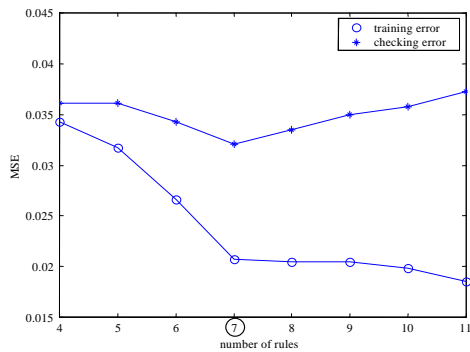


그림 6 초기 FCM-ANFIS의 규칙 선택
Fig. 6 Rule selection of initial FCM-ANFIS

표 1은 트럭 후진제어에 대한 결과로 제안된 방법이 기존의 방법에 비해서 적은 수의 규칙과 파라미터를 가지고 트럭 후진제어를 행할 수 있음을 알 수 있다. 또한 ANFIS와 제안된 방법을 비교해 본 결과 학습 데이터에 대한 조향각 오차는 각각 0.101, 0.119[rad]으로 비슷한 결과를 보였으나, 검증 데이터에 대한 조향각 오차는 각각 0.432, 0.147[rad]으로 차이가 남을 알 수 있다. 이는 ANFIS의 많은 규칙으로 인해 과도적합의 문제점을 보이는 반면, 제안된 방법에서는 이러한 문제가 없음을 나타낸다.




그림 7 GA 기반 퍼지 제어기에 의한 트럭의 궤적
Fig. 7 Truck trajectories by the proposed controller




그림 8 세대에 따른 학습 및 검증데이터 오차의 감소
Fig. 8 MSE of training data and checking data

표 1 파라미터와 규칙 수의 비교

Table 1 Comparison of parameter and rule numbers

method	rule	parameter
Wang[13]	27	85
Kosko[14]	35	85
Kim[15]	35	85
ANFIS	25	132
the suggested method	7	45

5. 결 론

본 논문에서는 GA를 이용하여 퍼지 제어기를 구축하는 방법에 대해서 다루었다. 제안된 제어기는 FCM 클러스터링과 ANFIS를 이용하여 초기 FCM-ANFIS를 구축하였으며, 이 시스템의 파라미터를 초기 집단으로 발생시켜 GA와 RLSE에 의해 파라미터 동정을 수행하였다. 이렇게 함으로써 ANFIS의 입력공간이 증가할 때 규칙의 수가 지수적으로 증가하는 문제점을 해결할 수 있고, BP 알고리즘과 같은 학습으로 인해 국소적인 최소점에 빠질 수 있는 문제점을 적용 GA를 이용하여 집단의 다양성 유지와 전역적인 최적해의 수렴을 가속화할 수 있었다. 제안된 제어기를 이용하여 트럭 후진제어에 적용해 본 결과 적은 규칙으로도 원하는 궤적을 그리면서 정확하게 주차함을 알 수 있었다. 제안된 방법은 제어기 설

계뿐만 아니라 분류기, 필터, 등화기 등 여러 응용분야에 적용이 가능하리라 생각된다.

참 고 문 헌

[1] E. H. Mamdani, "Applications of Fuzzy Algorithms for Control of Simple Dynamic Plant", Proceeding of IEEE, Vol. 121 No. 12, pp. 1585-1588, 1974.

[2] J. S. R. Jang, C. T. Sun, and E. Mizutani, Neuro-Fuzzy and Soft Computing : A Computational Approach to Learning and Machine Intelligence, Prentice Hall, 1997.

[3] C. T. Lin and C. S. G. Lee, Neural Fuzzy Systems : A Neuro-Fuzzy Synergism to Intelligent Systems, Prentice Hall, 1996.

[4] C. T. Sun, "Rule-Base Structure Identification in an Adaptive Network-Based Fuzzy Inference System", IEEE Trans. on Fuzzy Systems, Vol. 2, No. 1, pp. 64-73, 1994.

[5] J. S. Jang, "ANFIS : Adaptive-Network-Based Fuzzy Inference System", IEEE Trans. Syst. Man. Cybern., Vol. 23, pp. 665-685, 1993.

[6] X. S. Zhang and R. J. Roy, "Derived Fuzzy Knowledge Model for Estimation the Depth of Anesthesia", IEEE Trans. on Biomedical Engineering, Vol. 48, No. 3, pp. 312-323, 2001.

[7] D. H. Kim and C. K. Jung, "New 2-DOF PID Controller Tuning by Adaptive Neural Fuzzy Inference System for Gas Turbine Control System", Journal of Advanced Computational Intelligence, Vol. 4, No. 5, pp. 341-348, 2000.

[8] Bezdek J., Hathaway R., Sabin M., and Tucker W., Convergence Theory for Fuzzy C-means : Counter Examples and Repairs, CRC Press, 1987.

[9] K. C. Kwak, M. G. Chun, J. W. Ryu, and T. H. Han, "FCM-Based Adaptive Fuzzy Inference System for Coagulant Dosing Process in a Water Purification Plant", Journal of Knowledge-Based Intelligent Engineering Systems, Vol. 4, No. 4, pp. 230-236, 2000.

[10] D. E. Goldberg, Genetic Algorithms in Search, Optimization and Machine Learning, Addison-Wesley, MA, 1989.

[11] M. Srinivas and L. Patnaik, "Adaptive Probabilities of Crossover and Mutation in Genetic Algorithms", IEEE Trans. on Systems, Man, Cybern., Vol. 24, 1994.

[12] D. Nguyen and B. Widrow, "The Truck Backer-Upper : An Example of Self-Learning Control Systems", IEEE Control System Magazine, Vol. 10, No. 3, pp. 18-23, 1990

[13] S. G. Kong and B. Kosko, "Adaptive Fuzzy Systems for Backing Up a Truck and Trailer", IEEE Trans. on Neural Networks, Vol. 3, No. 2, pp. 211-223, 1992.

[14] L. X. Wang and J. M. Mendel, "Generating Fuzzy

Rules by Learning from Examples", IEEE Trans. on Systems, Man, and Cybern., Vol. 22, No. 6, pp. 1414-1427, 1992.

[15] D. Kim, "Improving the Fuzzy System Performance by Fuzzy System Ensemble", Fuzzy Sets and Systems, Vol. 98, pp. 43-56, 1998.

저 자 소 개



곽근창 (郭根昌)

1996년 충북대 전기공학과 졸업, 1998년 동대학원 전기공학과 졸업(석사), 2002년 동대학원 전기공학과 졸업(박사)
 Tel : 043) 261-2419
 Fax : 043) 261-3280
 E-mail : kckwak@engine.chungbuk.ac.kr



김주식 (金周植)

1992년 충북대 전기공학과 졸업, 1994년 동대학원 전기공학과 졸업(석사), 1998년 동대학원 전기공학과 졸업(박사), 1999년 ~2001년 (주)지엔티씨 기술개발실, 2001년 ~현재 충북대 전기전자및컴퓨터공학부 초빙전임강사.
 Tel : 043) 261-3330
 Fax : 043) 261-3280
 E-mail : kimjusik@cbucc.chungbuk.ac.kr



정수현 (鄭秀鉉)

1985년 충북대 전기공학과 졸업, 1987년 동대학원 전기공학과 졸업(석사), 2000년 동대학원 전기공학과 졸업(박사), 1995년 ~현재 대원과학대학 전기과 부교수.
 Tel : 043) 649-3211
 Fax : 043) 645-9170
 E-mail : shjeong@daewon.ac.kr