



저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#)

2022년 2월
박사학위논문

계층적인 구조와 정보입자할당에
근거한 퍼지기반 입자모델의 설계 및
최적화

조선대학교 대학원

제어계측공학과

염 찬 욱

계층적인 구조와 정보입자할당에 근거한 퍼지기반 입자모델의 설계 및 최적화

A Design and Optimization of Fuzzy-Based Granular Model
Based on Hierarchical Structures and the Allocation of
Information Granules

2022년 2월 25일

조선대학교 대학원

제어계측공학과

염 찬 욱

계층적인 구조와 정보입자할당에 근거한 퍼지기반 입자모델의 설계 및 최적화

지도교수 곽근창

이 논문을 공학 박사학위신청 논문으로 제출함

2021년 10월

조선대학교 대학원

제어계측공학과

염찬욱

염찬욱의 공학박사학위논문을 인준함

위원장 조선대학교 교수 고낙용



위원 조선대학교 교수 염흥기



위원 조선대학교 교수 신주현



위원 한국전자통신연구원 박사 김도형



위원 조선대학교 교수 곽근창



2022년 1월

조선대학교 대학원

목 차

제1장 서론	1
제1절 연구 배경	1
제2절 연구 목적	3
제3절 연구 내용	5
제2장 이론적 배경 및 관련 연구	7
제1절 퍼지 클러스터링	7
제2절 출력공간을 고려한 퍼지 클러스터링	9
제3절 GK 클러스터링	14
제3장 정보 입자 생성 및 입자 모델 설계	17
제1절 입자 컴퓨팅 및 정보 입자	17
제2절 합리적인 정보 입자 생성	18
제3절 퍼지 입자 모델	22
제4절 컨텍스트 기반 GK 클러스터링(CGK)	24
제5절 CGK 기반 입자 모델 설계	29
제4장 계층적 구조의 입자 모델 설계	33
제1절 계층적 구조의 CGK 기반 입자 모델 설계	33

제2절 집계형 구조의 CGK 기반 입자 모델 설계	35
제5장 정보 입자 할당을 통한 최적화된 계층적 입자 모델 설계	39
제1절 정보 입자의 최적 할당	39
제2절 최적의 정보 입자를 통한 계층적 구조의 CGK 기반 입자 모델 설계	43
제6장 실험 및 결과분석	46
제1절 데이터베이스	46
제2절 실험 및 결과분석	47
제7장 결론	91
참고문헌	93

그림 목차

그림 2.1. 비퍼지 클러스터링과 퍼지 클러스터링의 개념	8
그림 2.2. 출력공간을 고려한 퍼지 클러스터링의 개념	11
그림 2.3. 퍼지 클러스터링과 컨텍스트 기반 퍼지 클러스터링에서 생성된 클러스터 비교	12
그림 2.4. 퍼지 클러스터링과 GK 클러스터링에서 생성된 클러스터 비교	15
그림 3.1. 정보 입자의 형태	18
그림 3.2. 합리적인 정보 입자 생성을 위한 범위성 및 특이성의 개념	19
그림 3.3. 정보 입자의 범위성과 특이성의 상충 관계	22
그림 3.4. 퍼지 입자 모델의 구조	24
그림 3.5. 출력공간에 두 개의 특징을 가지고 있는 데이터집합	25
그림 3.6. GK 클러스터링과 컨텍스트 기반 GK 클러스터링에서 생 성된 클러스터 비교	26
그림 3.7. 컨텍스트 기반 GK 클러스터링의 개념	27
그림 3.8. CGK 입자 모델의 구조	32
그림 4.1. 계층적 구조의 입자 모델	35
그림 4.2. 선형회귀 모델의 개념	36
그림 4.3. 신경회로망의 구조	37
그림 4.4. 방사기저함수 신경망의 구조	37

그림 4.5. 집계형 구조의 CGK 기반 입자 모델의 구조	38
그림 5.1. 정보 입자화 방법을 통해 생성된 정보 입자의 형태 ·	41
그림 5.2. 합리적인 정보 입자 생성을 위한 출력공간에 생성되는 정보 입자의 변수 할당 과정	42
그림 5.3. 유전 알고리즘의 진행 순서	44
그림 5.4. 최적화된 CGK 기반 입자 모델의 구조	45
그림 5.5. 최적화된 집계형 구조의 CGK 기반 입자 모델의 구조	45
그림 6.1. 기존 GM의 출력 값과 실제 출력 값 비교	49
그림 6.2. 검증데이터에 대한 GM의 성능지표	50
그림 6.3. CGK-GM의 출력 값과 실제 출력 값 비교	52
그림 6.4. 검증데이터에 대한 CGK-GM의 성능지표	53
그림 6.5. AGM의 출력 값과 실제 출력 값 비교	55
그림 6.6. 검증데이터에 대한 AGM의 성능지표	56
그림 6.7. 최적화된 CGK-GM의 출력 값과 실제 출력 값 비교 ···	58
그림 6.8. 검증데이터에 대한 optimized CGK-GM의 성능지표 ···	58
그림 6.9. 최적화된 AGM의 출력 값과 실제 출력 값 비교	59
그림 6.10. 검증데이터에 대한 optimized AGM의 성능지표	60
그림 6.11. 최적화된 CGK-GM 내 유전 알고리즘의 적합도	60
그림 6.12. 최적화된 AGM 내 유전 알고리즘의 적합도	61
그림 6.13. 기존 GM의 출력 값과 실제 출력 값 비교	63
그림 6.14. 검증데이터에 대한 GM의 성능지표	64
그림 6.15. CGK-GM의 출력 값과 실제 출력 값 비교	66

그림 6.16. 검증데이터에 대한 CGK-GM의 성능지표	67
그림 6.17. AGM의 출력 값과 실제 출력 값 비교	69
그림 6.18. 검증데이터에 대한 AGM의 성능지표	70
그림 6.19. 최적화된 CGK-GM의 출력 값과 실제 출력 값 비교 ..	72
그림 6.20. 검증데이터에 대한 optimized CGK-GM의 성능지표 ..	72
그림 6.21. 최적화된 AGM의 출력 값과 실제 출력 값 비교	73
그림 6.22. 검증데이터에 대한 optimized AGM의 성능지표	73
그림 6.23. 최적화된 CGK-GM 내 유전 알고리즘의 적합도	74
그림 6.24. 최적화된 AGM 내 유전 알고리즘의 적합도	74
그림 6.25. 기존 GM의 출력 값과 실제 출력 값 비교	77
그림 6.26. 검증데이터에 대한 GM의 성능지표	78
그림 6.27. CGK-GM의 출력 값과 실제 출력 값 비교	80
그림 6.28. 검증데이터에 대한 CGK-GM의 성능지표	81
그림 6.29. AGM의 출력 값과 실제 출력 값 비교	83
그림 6.30. 검증데이터에 대한 AGM의 성능지표	84
그림 6.31. 최적화된 CGK-GM의 출력 값과 실제 출력 값 비교 ..	86
그림 6.32. 검증데이터에 대한 optimized CGK-GM의 성능지표 ..	86
그림 6.33. 최적화된 AGM의 출력 값과 실제 출력 값 비교	87
그림 6.34. 검증데이터에 대한 optimized AGM의 성능지표	88
그림 6.35. 최적화된 CGK-GM 내 유전 알고리즘의 적합도	88
그림 6.36. 최적화된 AGM 내 유전 알고리즘의 적합도	89

표 목차

표 6-1. 컨텍스트를 균등하게 생성한 GM의 성능지표	48
표 6-2. 컨텍스트를 유연하게 생성한 GM의 성능지표	48
표 6-3. 컨텍스트를 균등하게 생성한 CGK-GM의 성능지표	51
표 6-4. 컨텍스트를 유연하게 생성한 CGK-GM의 성능지표	51
표 6-5. 컨텍스트를 균등하게 생성한 AGM의 성능지표	54
표 6-6. 컨텍스트를 유연하게 생성한 AGM의 성능지표	54
표 6-7. 컨텍스트를 균등하게 생성한 optimized CGK-GM의 성능지표	57
표 6-8. 컨텍스트를 균등하게 생성한 optimized AGM의 성능지표	57
표 6-9. Optimized CGK-GM의 컨텍스트 최적화 후 업데이트된 값 확인	57
표 6-10. Optimized AGM의 컨텍스트 최적화 후 업데이트된 값 확인	57
표 6-11. 콘크리트 압축 강도 예측의 실험 결과	62
표 6-12. 컨텍스트를 균등하게 생성한 GM의 성능지표	62
표 6-13. 컨텍스트를 유연하게 생성한 GM의 성능지표	63
표 6-14. 컨텍스트를 균등하게 생성한 CGK-GM의 성능지표	65
표 6-15. 컨텍스트를 유연하게 생성한 CGK-GM의 성능지표	65

표 6-16. 컨텍스트를 균등하게 생성한 AGM의 성능지표	68
표 6-17. 컨텍스트를 유연하게 생성한 AGM의 성능지표	68
표 6-18. 컨텍스트를 유연하게 생성한 최적화된 CGK-GM의 성능지표	71
표 6-19. 컨텍스트를 유연하게 생성한 최적화된 AGM의 성능지표	71
표 6-20. 최적화된 CGK-GM의 컨텍스트 최적화 후 업데이트된 값 확인	71
표 6-21. 최적화된 AGM의 컨텍스트 최적화 후 업데이트된 값 확인	71
표 6-22. 정수장 응집제 투여량 예측의 실험 결과	75
표 6-23. 컨텍스트를 균등하게 생성한 GM의 성능지표	76
표 6-24. 컨텍스트를 유연하게 생성한 GM의 성능지표	76
표 6-25. 컨텍스트를 균등하게 생성한 CGK-GM의 성능지표	79
표 6-26. 컨텍스트를 유연하게 생성한 CGK-GM의 성능지표	79
표 6-27. 컨텍스트를 균등하게 생성한 AGM의 성능지표	82
표 6-28. 컨텍스트를 유연하게 생성한 AGM의 성능지표	82
표 6-29. 컨텍스트를 균등하게 생성한 최적화된 CGK-GM의 성능지표	85
표 6-30. 컨텍스트를 유연하게 생성한 최적화된 AGM의 성능지표	85

표 6-31. 최적화된 CGK-GM의 컨텍스트 최적화 후 업데이트된 값 확인	85
표 6-32. 최적화된 AGM의 컨텍스트 최적화 후 업데이트된 값 확인	85
표 6-33. 보스턴 주택 가격 예측의 실험 결과	90

ABSTRACT

A Design and Optimization of Fuzzy-Based Granular Model Based on Hierarchical Structures and the Allocation of Information Granules

Yeom, Chan-Uk

Advisor : Prof. Kwak, Keun Chang, Ph. D.
Dept. of Control and Instrumentation Eng.,
Graduate School of Chosun University

In this paper, we propose the design and optimization of a CGK-based granular model (CGK-GM) based on the hierarchical structure and optimal allocation of information granules. In general fuzzy clustering, the Euclidean distance between the center of the cluster and each data is calculated by considering the characteristics of the data in the input space. A circle-shaped cluster is generated using the obtained Euclidean distance. When the data are geometrical features, there is a problem that the performance of fuzzy clustering decreases. To improve this problem, GK(Gustafuson-Kessel) clustering is used to generate clusters that take geometrical features into account. In the existing GK clustering, the distance between the center of the cluster and the data is calculated using the Mahalanobis distance in consideration of the characteristics of the data in the input space. Using the Mahalanobis distance, a geometrical cluster is created based on the center of the cluster. In this paper, we propose context-based GK clustering that considers the output space from the

existing GK clustering. Since the existing GK clustering considers only the input space, clusters are created using only the features of the input space. On the other hand, context-based GK clustering can create clusters more efficiently than conventional GK clustering because it considers the characteristics of data in the output space as well as the input space.

The CGK-based granular model designed using the proposed CGK clustering is an explanatory model that can create contextual information granules in the output space and geometric information granules in the input space to automatically generate rules and express them verbally. To design the CGK-based granular model that automatically generates rules has a problem in that the number of rules increases exponentially when processing large-scale data. To solve this problem, the proposed CGK-based granular model and general prediction models are combined in a hierarchical structure to design an aggregated CGK-based granular model. In addition, in order to improve the prediction performance of the hierarchical CGK-based granular model, one of the optimization algorithms, the genetic algorithm, is used to optimize the information granules to generate the optimal information granules, and use this to optimize the CGK-based hierarchical structure. Design the granular model.

To verify the validity of the proposed methods, we compare and analyze the prediction performance with the existing particle model using the prediction-related benchmarking database, the concrete compressive strength database, the water purification plant coagulant dose database, and the Boston housing price database. As a result of the experiment, the proposed CGK-based granular model, the CGK-based granular model with an aggregated structure, the optimized CGK-based granular model, and the CGK-based granular model with the optimized aggregated structure showed better prediction performance than the conventional granular model. confirmed what was visible.

약어 정리

약어	용어
FCM	Fuzzy C-Means
CFCM	Context-based Fuzzy C-Means
IFCM	Interval-based Fuzzy C-Means
IG	Information Granules
GM	Granular Model
PI	Performance Index
GK	Gustafuson-Kessel
CGK	Context-based GK
CGK-GM	CGK based Granular Model
AGM	Aggregated structure of Granular Model

제1장 서론

제1절 연구 배경

인공지능(AI, Artificial Intelligent) 분야에서 추론 엔진(inference engine)은 새로운 정보를 추론하기 위해 지식 기반에 논리적 규칙을 적용하는 시스템의 구성요소이며 최초 추론 엔진은 전문가 시스템(expert system)이다. 일반적인 전문가 시스템은 지식 기반과 추론 엔진으로 구성된다. 지식 기반은 실세계에 대한 정보를 저장하고 있고 추론 엔진은 지식 기반 및 추론된 새로운 지식에 논리적 규칙을 적용한다. 이 과정은 지식 기반의 각각의 새로운 정보가 추론 엔진에서 추가 규칙을 생성할 수 있게 한다. 이러한 전문가 시스템으로는 퍼지 추론 시스템이 있다. 퍼지 추론 시스템은 의사결정을 기본 작업으로 하는 퍼지 논리 시스템의 핵심 단위로서 필수 결정 규칙을 생성하기 위해 논리 게이트 'OR' 또는 'AND' 와 함께 'IF-THEN' 규칙을 사용한다.

퍼지 추론 시스템은 크게 맘다니(Mamdani)형, 수게노(Sugeno)형으로 나누어진다. 맘다니형 추론 시스템은 전문가로부터 얻어진 일련의 언어 제어 규칙을 합성하여 만들어지며 각 규칙의 출력은 퍼지 집합 형태를 나타낸다. 또한 직관적이고 이해하기 쉬운 규칙 기반을 갖추고 있으므로 규칙이 의료 진단과 같은 인간의 전문 지식에서 생성되는 전문가 시스템 적용 분야에 활용이 적합하다. 수게노형 추론 시스템은 Takagi-Sugeno-Kang 추론 시스템이라고도 불리며 상수 또는 입력값의 선형 함수 형태인 단일 출력 소속함수를 사용한다. 수게노형 추론 시스템은 역퍼지화 과정을 포함하고 있어 2차원 영역의 중심을 계산하는 대신 몇 가지 데이터 포인트의 가중 평균 또는 가중 합계를 사용하기 때문에 맘다니형 추론 시스템과 비교해 계산 효율성이 높은 장점이 있다. 이러한 퍼지 추론 시스템들은 다양한 예측 분야에 적용되고 있으며 활발히 연구되고 있다[1-9]. An [10]은 교통량 예측의 핵심적인 부분인 교통 흐름을 예측하기 위해 퍼지 추론과 합성곱신경망(CNN, Convolutional Neural Network)을 결합한 F-CNN을 제안했다. Yeom [11]은 컨텍스트 기반 퍼지 클러스터링을 기반으로 점증적인 구조의 적응형 뉴로-퍼지 추론 시스템(ANFIS, Adaptive Neuro-Fuzzy Inference System)을 제안했다. Parsapoor

[12]은 태양 활동을 예측하기 위해 뇌 감정 학습 기반 퍼지 추론 시스템(BELFIS, Brain Emotional Learning-based Fuzzy Inference System)을 제안했다. Kannadasan [13]는 가공 부품 제조에 중요한 역할을 하는 CNC(Computer Numerical Control)에서 표면 거칠기 및 기하 공차와 같은 성능 지수를 예측하기 위해 지능형 예측 모델을 제안했다. Guo [14]는 시계열 예측을 위한 차원 및 퍼지 추론 시스템을 임베딩하기 위해 대칭 기하학을 사용하는 역전파(BP, Back Propagation) 기반 커널 함수 GC(Graner Causality)라는 모델을 제안하여 뇌 영역 간의 인과 관계 영향을 조사했다. Hwang [15]은 발뒤꿈치를 떼고 보행 초기 단계에서 갑작스러운 보행자 움직임의 정상 보행 속도를 예측하기 위해 모션 큐(cue) 기반 퍼지 추론 시스템을 제안했다.

신경망 전문가 시스템은 인공 신경망과 전문가 시스템을 결합한 것으로 인간의 지능을 모방한 전문가 시스템이다. 일반적인 전문가 시스템의 경우 결정 트리 및 논리 추론을 이용하여 인간의 추론 방식을 설계했다면, 인공 신경망은 인간의 뇌의 구조 및 학습 능력에 주목하여 이를 지식 표현에 반영한다. 이 두 가지 시스템을 결합하면 전문가 시스템을 통해 결과를 도출하는 과정을 확인할 수 있고 인공 신경망을 통해 사용자가 개입하지 않고 학습할 수 있다. 따라서 기존의 개별 시스템보다 효과적인 추론이 가능한 시스템을 만들 수 있다. 이러한 신경망 전문가 시스템에 관한 연구는 다음과 같이 진행되고 있다[16-20]. Liu [21]는 운전 피로 예측을 위한 뇌 역학에서 뇌파 회귀 문제를 해결하기 위해 온라인 경사하강법 학습 규칙을 사용하는 순환 자기 진화 퍼지 신경망(RSEFNN, Recurrent Self-Evolving Fuzzy Neural Network)을 제안했다. Dumas [22]는 내부 이미지 예측을 위해 완전연결신경망과 합성곱신경망을 기반으로 하는 예측 신경망(PNN, Prediction Neural Network)을 제안했다. Lin [23]은 지진 규모 예측을 위한 두 개의 은닉층으로 구성된 임베디드 역전파 신경망을 제안했다.

예측 분야에서 연구되고 있는 방법으로 자기회귀누적이동평균(ARIMA, Auto Regressive Integrated Moving Average) 모델이 있다. 자기회귀누적이동평균 모델은 자기회귀이동평균(ARMA, Auto Regressive Moving Average) 모델과 달리 과거의 데이터에서 파악할 수 있는 추세(momemtum)까지 반영함으로써 상관관계(correlation)뿐만 아니라 공적분(cointegration)까지 고려하는 방법이다. 자기회귀누적이동평균 모델에 대한 연구는 다음과 같이 진행되고 있다[24-27]. Pati [28]는 소프트웨어 클론 진화 예측을 확인하기 위해 자기회귀누적이동평균 모델,

역전파 신경망, 다중 목표 유전자(MOG, Multi Objective Genetic) 알고리즘의 성능을 비교하였다. Meysam [29]는 자기회귀누적이동평균 모델과 혼돈 시스템을 사용하여 새로운 DoS 및 DDoS 공격을 탐지하는 방법을 제안했다. Yan [30]는 절단된 SVD(Singular Value Decomposition) 기반 자기회귀누적이동평균 모델을 이용하여 모바일 에지 컴퓨팅 환경에서 다중 QoS를 예측하는 방법을 제안했다.

제2절 연구 목적

앞에서 언급했던 퍼지 추론 시스템, 인공 신경망, 자기회귀누적이동평균 모델들은 서로 다른 처리 과정을 가지고 다양한 예측 문제를 해결해왔다. 또한, 한 가지 방법이 아닌 두 가지 이상의 서로 다른 방법을 결합하여 예측 문제를 해결하는 연구들도 진행되고 있다. 서로 다른 방법이 결합한 추론 시스템을 하이브리드 시스템(hybrid system)이라 하고 하이브리드 시스템을 구축하는 방법으로 입자 컴퓨팅(GrC, Granular Computing) [31, 32] 방법이 사용되고 있다. 입자 컴퓨팅 방법은 데이터 및 정보에서 지식을 추출하고 데이터를 추상화하는 과정에서 발생하는 ‘정보 입자(IG, Information Granule)’ 라고 하는 정보 개체의 처리와 관련된 컴퓨팅 이론이다.

일반적으로 사용되는 퍼지 추론 시스템, 인공 신경망, 딥러닝에서 사용되는 컴퓨팅에서는 모델 출력값이 크리스프(crisp) 형태 또는 숫자로 나타난다. 모델 출력값이 값이 분명한 크리스프 형태나 숫자일 경우 실제 출력값과의 수치적인 오차를 계산할 수 있지만, 모델 출력과 실제 출력의 차이를 언어적으로 표현하고 해석하는데 어려움이 발생한다. 하지만, 입자 컴퓨팅에서는 모델 출력값이 소프트(soft) 형태 또는 퍼지 집합 등으로 나타나기 때문에 경계가 모호하거나 불확실하고 불완전한 데이터 및 정보를 다루고 처리할 때 효과적이다. 실세계에서 인간은 수치적인 표현보다 언어적인 표현을 주로 사용하며, 불확실하고 불완전한 환경에서 추론하는 뇌는 수치적인 값이 아닌 언어적인 값을 통해 추론하고 결정한다. 이처럼 입자 컴퓨팅은 인간이 사고하고 결정하는 과정을 나타낼 수 있다. 입자 컴퓨팅을 이용한 연구들은 다음과 같이 진행되고 있다[33-37]. Zhu [38]는 입자화된 입력공간의 개발 및 분석과 그에 따른 입자화된 모델 설계에 대한 새로운 접근 방법을 제안했다. Truong [39]은 이상 값 감지 문제를 해결하기 위해 FPCM(Fuzzy

Possibilistic C-Means) 클러스터링 및 입자 컴퓨팅 방법을 제안했다. Zuo [40]는 입자 컴퓨팅을 전이 학습에 적용하기 위해 세 가지 입자화된 퍼지 회귀 도메인 적응 방법을 제안했다. Hu [41]는 입자 컴퓨팅을 이용해 퍼지 규칙 기반 모델을 입자화하고 제안된 모델을 평가하는 방법을 제안했다. Zhao [42]는 퍼지 클러스터링을 통해 생성된 정보 입자 기반 입자 모델을 설계하여 철강 산업의 에너지 시스템에 대한 장기 예측을 수행했다. 위 연구를 분석한 결과, 입자 컴퓨팅을 통해 생성된 정보 입자를 생성하고 이를 이용하여 입자 모델(GM, Granular Model)을 설계하여 소프트 형태 출력을 계산해 언어적인 표현이 가능하게 되었다. 또한, 소프트 형태 출력의 예측 성능을 평가할 수 있는 성능 평가 방법이 제안되고 있다. 하지만, 정보 입자의 생성 방법, 형태, 크기 설정 등 최적의 정보 입자를 생성하여 입자 모델의 예측 성능을 향상하는 연구가 필요하다.

일반적인 퍼지 클러스터링은 입력공간에서 클러스터의 중심으로부터 원 형태의 클러스터를 생성한다. 하지만, 입력공간의 데이터가 기하학적 특징을 가질 때 클러스터링이 제대로 되지 않는 문제가 발생한다. 이러한 문제를 보완하기 위해 데이터의 기하학적 특징을 고려하여 클러스터를 생성할 수 있는 GK(Gustafuson-Kessel) 클러스터링이 사용된다. 본 논문에서는 기하학적 형태의 클러스터를 생성하는 기존의 GK 클러스터링에서 입력공간뿐만 아니라 출력공간까지 고려하는 컨텍스트 기반 GK(CGK, Context-based GK) 클러스터링을 제안한다. 제안된 컨텍스트 기반 GK 클러스터링을 이용하여 출력공간에서 컨텍스트 형태의 정보 입자를 생성하고 입력공간에서 기하학적 형태의 정보 입자를 생성하는 CGK 기반 입자 모델을 설계한다. 또한, 대규모 데이터를 사용할 경우 규칙의 수가 기하학적으로 증가하는 문제점을 해결하기 위해 의미 있는 규칙을 생성할 수 있도록 CGK 기반 입자 모델과 일반적인 예측 모델들을 집계형 구조로 결합하여 계층적 구조의 CGK 기반 입자 모델을 설계하고 최적화 알고리즘은 유전 알고리즘을 이용하여 정보 입자를 최적 할당하여 최적화된 계층적 구조의 CGK 기반 입자 모델을 제안한다.

제3절 연구 내용

본 논문에서는 컨텍스트 기반 GK 클러스터링을 이용하여 CGK 기반 입자 모델을 설계한다. 일반적인 퍼지 클러스터링은 입력공간에 있는 데이터의 특징을 고려하여 클러스터의 중심과 각각의 데이터 사이의 유클리디안 거리를 구한다. 구해진 유클리디안 거리를 이용하여 원 형태의 클러스터를 생성한다. 일반적인 퍼지 클러스터링은 입력공간만 고려하여 클러스터를 생성하기 때문에 클러스터를 생성할 때 정확성이 떨어지는 문제가 발생한다. 이러한 문제를 해결하기 위해 출력공간을 고려하는 퍼지 클러스터링인 컨텍스트 기반 퍼지 클러스터링과 구간 기반 퍼지 클러스터링이 사용된다. 출력공간을 고려하는 퍼지 클러스터링은 출력공간에 있는 데이터의 특징을 고려하기 때문에 클러스터를 정확하게 생성할 수 있다. 하지만, 데이터가 기하학적 특징이 강할 경우 클러스터의 정확성이 감소할 수 있다. 이러한 문제를 개선하기 위해 기하학적 특징을 고려하여 클러스터를 생성하는 GK(Gustafson-Kessel) 클러스터링이 사용된다. 기존의 GK 클러스터링은 입력공간에 있는 데이터의 특징을 고려하여 클러스터의 중심과 데이터 사이의 거리를 마할라노비스 거리를 이용하여 계산한다. 그리고 마할라노비스 거리를 이용하여 클러스터의 중심을 기준으로 기하학적 형태의 클러스터를 생성한다. 기존의 GK 클러스터링은 입력공간만 고려하기 때문에 입력공간의 특징으로 클러스터를 생성한다. 하지만, 컨텍스트 기반 GK 클러스터링은 입력공간뿐만 아니라 출력공간에 있는 데이터의 특징을 고려하여 클러스터를 생성하여 기존의 GK 클러스터링보다 효율적으로 클러스터를 생성할 수 있다. 따라서, 본 논문에서는 기존의 GK 클러스터링에서 출력공간까지 고려하는 컨텍스트 기반 GK 클러스터링을 제안한다. 제안된 컨텍스트 기반 GK 클러스터링을 이용하여 설계된 CGK 입자 모델은 출력공간에 컨텍스트 형태의 정보 입자를 생성하고 입력공간에 기하학적 형태의 정보 입자를 생성하여 규칙을 자동으로 생성하고 모델 출력을 언어적으로 표현할 수 있는 설명 가능한 출력을 나타낸다. 규칙을 자동으로 생성하는 CGK 입자 모델은 대규모 데이터를 처리할 때 규칙의 수가 기하급수적으로 증가하는 문제가 있다. 이러한 문제를 해결하기 위해 제안된 CGK 기반 입자 모델과 일반적인 예측 모델들을 계층적 구조로 결합하여 집계형 구조의 CGK 기반 입자 모델을 설계한다. 또한, 계층적 구조의 CGK 기반 입자 모델의 예측 성능을 향상시키기 위해 최적화 알고리즘 중 하나인

유전 알고리즘을 이용하여 정보 입자를 최적화하여 최적의 정보 입자를 생성하고 이를 이용하여 최적화된 계층적 구조의 CGK 기반 입자 모델을 제안한다.

본 논문에서 제안하는 방법은 다음과 같다. 출력공간에서 컨텍스트를 생성하고 입력공간에서 기하학적 형태의 정보 입자를 생성할 수 있는 CGK 클러스터링을 제안한다. 제안된 CGK 클러스터링 기반 입자 모델 및 계층적 구조의 CGK 기반 입자 모델을 설계하고 유전 알고리즘을 이용하여 정보 입자를 최적 할당하여 최적화된 CGK 기반 입자 모델 및 최적화된 계층적 구조의 CGK 기반 입자 모델을 설계하여 예측 성능을 개선한다. 본 논문의 구성은 다음과 같다. 2장에서 퍼지 클러스터링과 GK 클러스터링에 관해 설명하고 3장에서 정보 입자와 기존의 입자 모델 및 제안하는 방법인 컨텍스트 기반 GK 클러스터링과 CGK 기반 입자 모델에 관해 설명한다. 4장에서 집계형 구조로 결합된 계층적 구조의 CGK 기반 입자 모델에 관해 설명하고 5장에서 유전 알고리즘을 이용하여 정보 입자를 최적 할당한 최적화된 계층적 구조의 입자 모델에 관해 설명한다. 6장에서는 제안하는 방법의 타당성을 검증하기 위해 예측 관련 벤치마킹 데이터를 이용하여 성능을 분석한다. 마지막으로 7장에서 논문의 결론과 향후 연구 계획을 제시한다.

제2장 이론적 배경 및 관련 연구

제1절 퍼지 클러스터링

클러스터링은 같은 클러스터에 있는 데이터가 다른 클러스터에 있는 데이터보다 서로 더 유사하도록 데이터 세트를 클러스터화하는 작업이다. 데이터 탐색 및 분석에 주로 사용되며, 이미지 분석, 생물 정보학, 패턴 인식, 기계 학습 등 다양한 분야에서 사용되는 데이터 분석 방법이다[43-45]. ‘클러스터링’의 개념은 명확하게 정의할 수 없으므로 다양한 클러스터링 알고리즘이 존재한다. 연결 기반 클러스터링(connectivity based clustering), 중심 기반 클러스터링(centroid based clustering), 분배 기반 클러스터링(distribution based clustering), 밀도 기반 클러스터링(density based clustering), 그리드 기반 클러스터링(grid based clustering) 등이 있으며 대표적인 클러스터링 방법으로는 퍼지 클러스터링이 있다.

퍼지 클러스터링은 Dunn에 의해 개발되었고, Bezdek [46]에 의해 개선된 방법으로서 임의의 데이터가 둘 이상의 클러스터에 소속될 수 있는 특징을 가지고 있다. 비퍼지 클러스터링은 임의의 데이터가 정확히 하나의 클러스터에만 속할 수 있으므로 별개의 클러스터로 나뉘게 된다. 퍼지 클러스터링은 데이터가 소속값에 따라 둘 이상의 클러스터에 속할 수 있다. 예를 들어, 바나나는 노랑 또는 초록(비퍼지 클러스터링 기준)일 수 있지만, 노랑 및 초록(퍼지 클러스터링 기준)일 수도 있다. 여기서, 바나나는 전체 중 일정 부분이 노란색일 수도 있고 초록색일 수도 있다. 바나나가 초록색(초록색 = 1)에 속하고 노란색(노란색 = 0)이 아닌 초록색(초록색 = 0.5)과 노란색(노란색 = 0.5)에 속할 수 있다. 소속 값은 0과 1 사이로 나타낼 수 있으며 소속 값의 총합은 1이 된다. 소속 값은 임의의 데이터에 할당된다. 이러한 소속 값은 데이터가 각각의 클러스터에 소속하는 정도를 수치상으로 나타낸다. 낮은 소속 값을 갖게 되면 해당 클러스터의 가장자리에 있음을 알 수 있고 반대로, 높은 소속 값을 갖게 되면 해당 클러스터의 중심부에 있음을 알 수 있다. 그림 2.1. 은 비퍼지 클러스터링과 퍼지 클러스터링의 개념을 보여준다. 비퍼지 클러스터링의 경우 데이터가 하나의 집합에만 소속하는 반면에 퍼지 클러스터링은 데이터가 하나의 이상의 집합에 소속 값을 이용하여 소속하는 것을 확인

할 수 있다. 퍼지 클러스터링의 경우 소속 값을 이용하기 때문에 실생활에 애매모호한 데이터를 처리하는데 효과적이다.




그림 2.1. 비퍼지 클러스터링과 퍼지 클러스터링의 개념

퍼지 클러스터링은 다음 식으로 일반화할 수 있다.

$$J_m = \sum_{i=1}^N \sum_{k=1}^c u_{ki}^m d^2(x_i, v_k) \quad (2.1)$$

$$\sum_{k=1}^c u_{ki} = 1, \quad \forall i \in \{1, 2, \dots, N\} \quad (2.2)$$

여기서, $X = \{x_1, x_2, \dots, x_N\} \subseteq R^{N \times D}$ 은 데이터를 나타내며, $x_i \in R^{1 \times D}$ 는 데이터 항목을 나타낸다. N 은 데이터 항목의 수를 나타내며, c 는 $2 \leq c \leq N$ 인 클러스터의 수를 나타낸다. $u_{ki} \in R$ 은 k 번째 x_i 의 소속 값을 나타내며 $m \in Z^+$ 는 퍼지 소속 값에 대한 퍼지화 계수를 나타낸다.

클러스터 중심과 퍼지 소속함수는 수식 (2.2) 에 정의된 제약조건에 따라 (2.1) 을 최소화함으로써 반복 과정을 통해 얻어진다. 그러므로, 라그랑주 승수를 사용하여 목적 함수는 다음과 같이 수정된다.

$$J_m = \sum_{i=1}^N \left(\sum_{k=1}^c u_{ki}^m d^2(x_i, v_k) + \lambda_i \left(1 - \sum_{k=1}^c u_{ki} \right) \right) \quad (2.3)$$

여기서, λ_i 는 라그랑주 승수를 나타낸다. 따라서, 클러스터링 문제는 수식 (2.3)을 최소화하여 클러스터 중심 집합 $v^* = \{v_k^*, \forall k \in \{1, 2, \dots, c\}\}$ 와 퍼지 소속함수 집합 $U^* = \{u_{ki}^*, \forall k \in \{1, 2, \dots, c\}, \forall i \in \{1, 2, \dots, N\}\}$ 을 찾는 것으로 귀결된다. 클러스터의 중심 v_k^* 에 대한 최소화는 수식 (2.4), 퍼지 소속함수 u_{ki}^* 에 대한 최소화는 수식 (2.5)에서 다음과 같이 얻어진다.

$$v_k^* = \frac{\sum_{i=1}^N u_{ki}^m x_i}{\sum_{i=1}^N u_{ki}^m} \quad (2.4)$$

$$u_{ki}^* = \frac{1}{\sum_{j=1}^c \left(\frac{d^2(x_i, v_k)}{d^2(x_i, v_j)} \right)^{\frac{1}{(m-1)}}} \quad (2.5)$$

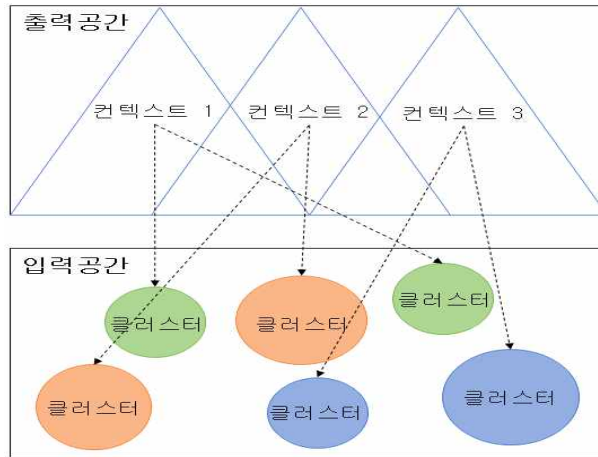
수식 (2.4)와 (2.5)는 클러스터의 최종 중심과 퍼지 소속함수를 얻기 위해 반복적으로 계산이 수행된다.

제2절 출력공간을 고려한 퍼지 클러스터링

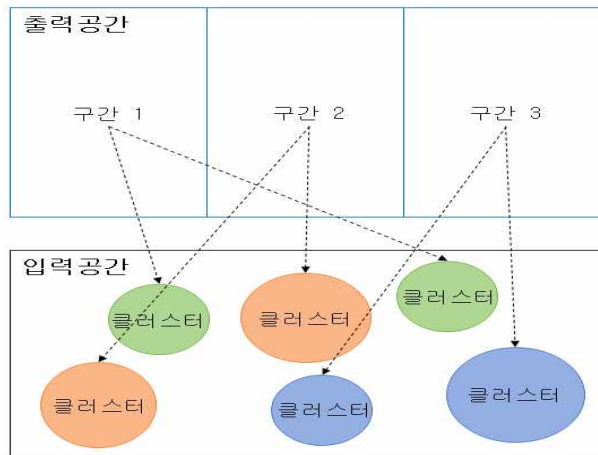
앞에서 설명한 퍼지 클러스터링은 입력공간에 있는 데이터의 특징을 고려한 클러스터링이다. 출력공간을 고려한 퍼지 클러스터링은 입력공간에 있는 데이터의 특징뿐만 아니라 출력공간에 있는 데이터의 유사성과 특징을 고려하여 클러스터를 생성한다. 출력공간을 고려하는 퍼지 클러스터링은 출력공간을 분할하는 형태에 따라 컨텍스트 기반 퍼지(CFCM, Context-based fuzzy C-Means) 클러스터링, 구간 기반 퍼지(IFCM, Interval-based Fuzzy C-Means) 클러스터링[47] 등이 있다. 그림 2.2.는 출력공간을 고려한 퍼지 클러스터링을 나타낸다. 그림 2.2. (a)는 출력공간에 삼각형 형태의 정보 입자인 컨텍스트(퍼지 집합)를 생성하고 각각의 컨텍스트

트에 해당하는 입력공간에서 클러스터를 생성한다. 그림 2.2. (b) 는 출력공간에 구간(interval) 형태의 정보 입자를 생성하고 각각의 구간에 해당하는 입력공간에서 클러스터를 생성한다.

일반적인 퍼지 클러스터링은 출력공간에 있는 데이터의 특징을 고려하지 않고 클러스터의 중심과 입력공간에 있는 데이터들 사이의 유클리디안(euclidean) 거리만을 사용하여 클러스터를 생성한다. 반면에, 컨텍스트 기반 퍼지 클러스터링은 Pedrycz [48, 49]에 의해 제안된 방법으로 출력공간에 삼각형 형태의 컨텍스트(퍼지 집합)를 생성하고 각 컨텍스트에서 퍼지 클러스터링을 통해 클러스터를 생성하기 때문에 기존의 퍼지 클러스터링보다 더 정교하게 클러스터를 생성할 수 있다. 그림 2.3. (a) 는 일반적인 퍼지 클러스터링을 그림 2.3. (b) 는 출력공간의 특징을 고려하는 컨텍스트 기반 퍼지 클러스터링에서 생성된 클러스터를 나타낸다.



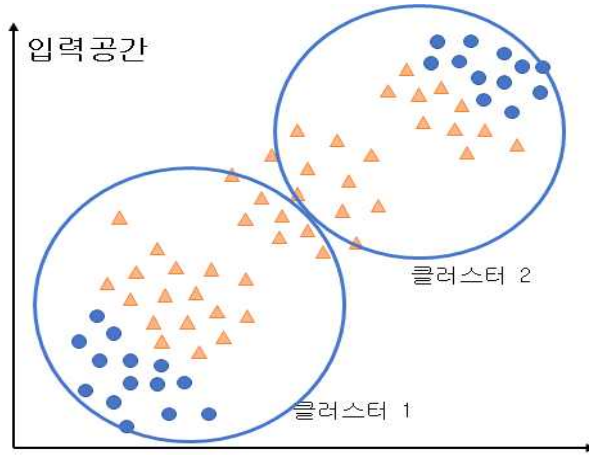
(a) 컨텍스트 기반 퍼지 클러스터링의 개념



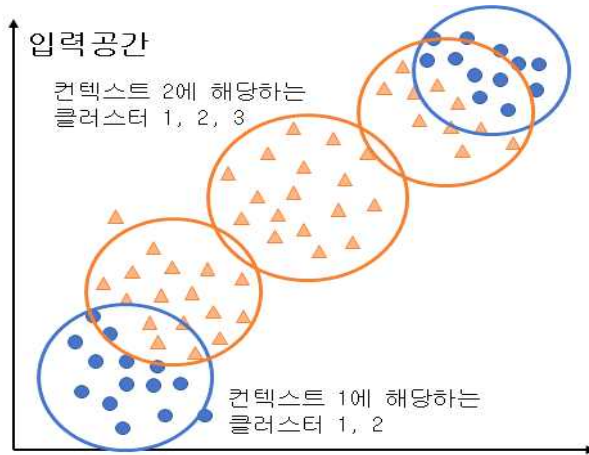
(b) 구간 기반 퍼지 클러스터링의 개념

그림 2.2. 출력공간을 고려한 퍼지 클러스터링의 개념

그림 2.3.과 같이 퍼지 클러스터링은 출력공간에 있는 데이터의 특성을 고려하지 않고 클러스터의 중심과 입력공간에 있는 데이터와의 거리를 이용하여 클러스터를 생성한다. 반면, 컨텍스트 기반 퍼지 클러스터링은 출력공간에 있는 데이터의 특성을 고려하여 클러스터를 생성하기 때문에 기존의 퍼지 클러스터링보다 클러스터를 효율적으로 생성할 수 있다.



(a) 퍼지 클러스터링에서 생성된 클러스터



(b) 컨텍스트 기반 퍼지 클러스터링에서 생성된 클러스터

그림 2.3. 퍼지 클러스터링과 컨텍스트 기반 퍼지 클러스터링에서 생성된 클러스터 비교

출력공간에 있는 데이터에 대한 컨텍스트는 $D: T \rightarrow [0,1]$ 과 같이 나타낼 수 있다. d 는 출력공간에 있는 전체 데이터를 나타낸다. 여기서, 임의의 데이터에 대한 컨텍스트를 이용할 수 있다고 가정한다. $f_k = T(d_k)$ 는 출력공간에 생성된 컨텍스트에서 k 번째 데이터의 소속된 정도를 나타낸다. f_k 는 0과 1 사이의 값으로 나타낼 수 있으며 위와 같은 특성에 의해 소속 행렬의 요구 사항을 수식 (2.6) 과 같이 나타

낼 수 있다.

$$U(f) = \left\{ \begin{array}{l} u_{ik} \in [0, 1] \mid \sum_{i=1}^c u_{ik} = f_k \forall k \\ \text{and } 0 < \sum_{k=1}^N u_{ik} < N \end{array} \right\} \quad (2.6)$$

$$u_{ik} = \frac{f_k}{\sum_{j=1}^c \left(\frac{\|x_k - c_i\|}{\|x_k - c_j\|} \right)^{\frac{2}{m-1}}} \quad (2.7)$$

수식 (2.6) 을 통해 최신했된 소속 행렬 U 는 수식 (2.7) 과 같이 나타낼 수 있다. 여기서, m 은 퍼지화 계수를 나타내며 일반적으로 $m=2$ 로 사용한다. 컨텍스트는 출력공간을 퍼지 집합 형태로 균등(uniform)하게 분할하여 소속 정도인 f_k 를 얻는다. 일반적으로 출력공간을 균등하게 분할하지만, 데이터의 특징에 따라 가우시안 확률 분포(gaussian distribution)에 따라 유연(flexible)하게 분할할 수 있다. 컨텍스트 기반 퍼지 클러스터링의 진행 순서는 다음과 같다.

[단계 1] 언어적으로 표현 가능한 컨텍스트의 수와 각각의 컨텍스트에서 생성될 클러스터의 수를 선택하고 0과 1 사이의 임의의 값으로 구성된 소속 행렬 U 를 초기화한다. 컨텍스트의 수와 클러스터의 수는 동일하게 설정할 수 있으며, 사용자에게 따라 서로 다른 값을 설정할 수 있다.

[단계 2] 출력공간을 퍼지 집합 형태로 균등하게 분할하여 일정한 크기의 언어적인 표현이 가능한 컨텍스트를 생성한다. 또한, 가우시안 확률 분포를 이용하여 유연하게 출력공간을 분할하여 서로 다른 크기의 컨텍스트를 생성할 수 있다.

[단계 3] 수식 (2.8) 을 이용하여 각각의 컨텍스트에서 클러스터의 중심을 계산한다.

$$c_i = \frac{\sum_{k=1}^N u_{ik}^m x_k}{\sum_{k=1}^N u_{ik}^m} \quad (2.8)$$

[단계 4] 수식 (2.9) 와 수식 (2.10) 을 이용하여 목적 함수를 계산한다. 여기서, 계산된 값이 이전 목적 함수 값을 비교하여 설정된 임계 값보다 큰 경우 위 과정을 반복하고, 작을 경우 멈춘다.

$$J = \sum_{i=1}^c \sum_{k=1}^N u_{ik}^m d_{ik}^2 \quad (2.9)$$

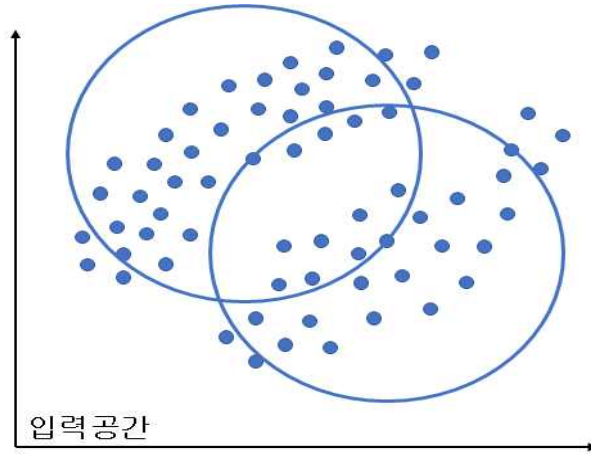
$$|J^h - J^{h-1}| \leq \epsilon \quad (2.10)$$

여기서, d_{ik} 는 k 번째 데이터와 i 번째 클러스터 중심과의 유클리디안 거리를 나타내며 h 는 반복된 횟수를 나타낸다.

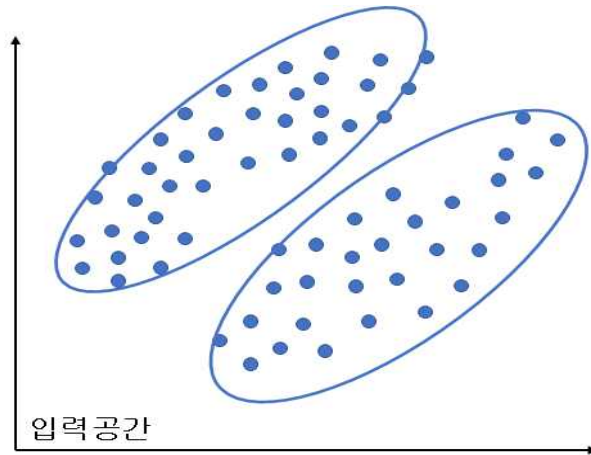
[단계 5] 수식 (2.7) 을 이용하여 소속 행렬 U 를 최신화하고 단계 3을 진행한다.

제3절 GK 클러스터링

입력공간에 있는 데이터를 클러스터에 소속하게 하는 것은 일반적으로 각각의 클러스터의 중심과 데이터 사이의 거리로 결정된다. 1절에서 설명한 퍼지 클러스터링은 유클리디안 거리를 이용하여 클러스터를 생성한다. 유클리디안 거리는 구형(circle shape)의 클러스터를 생성할 때 주로 사용되지만, 구형이 아닌 클러스터를 생성할 수 없는 문제점이 있다. 위와 같은 문제점을 해결하기 위해 기하학적 형태의 클러스터를 생성할 수 있는 GK 클러스터링 [50-52]이 제안되었다. GK 클러스터링은 클러스터의 중심과 데이터 사이의 거리를 유클리디안 거리가 아닌 마할라노비스 거리를 이용하여 계산한다. 그림 2.4.는 퍼지 클러스터링과 GK 클러스터링에서 생성된 클러스터를 나타내며, 수식 (2.11) 은 마할라노비스 거리를 나타낸다.



(a) 퍼지 클러스터링에서 생성된 클러스터



(b) GK 클러스터링에서 생성된 클러스터

그림 2.4. 퍼지 클러스터링과 GK 클러스터링에서 생성된 클러스터 비교

$$d_{GK}^2(x_k, v_i) = \|x_k - v_i\|_{A_i}^2 = (x_k - v_i)^T A_i (x_k - v_i) \quad (2.11)$$

여기서, d_{GK}^2 는 i 번째 클러스터의 중심 v_i 와 k 번째 데이터 x_k 사이의 거리를 제곱한 값을 나타내며, A_i 는 i 번째 클러스터의 분산 행렬을 나타낸다. GK 클러스터링은 수식 (2.11) 에 있는 분산 행렬 A_i 를 수식 (2.12) 을 이용하여 계산한다.

$$A_i = \frac{\sum_{k=1}^N u_{ik}^m (x_k - v_i)(x_k - v_i)^T}{\sum_{k=1}^N u_{ik}^m} \quad (2.12)$$

수식 (2.12) 을 이용하여 계산된 분산 행렬은 수식 (2.13)에서 클러스터의 중심과 데이터 사이의 거리를 계산할 때 사용된다.

$$D_{GK}^2 = (x_k - v_i)^T \left[\rho_i \det(A_i)^{\frac{1}{N}} A_i^{-1} \right] (x_k - v_i) \quad (2.13)$$

여기서, ρ_i 는 각각의 클러스터의 부피를 나타내며, 수식 (2.13) 에서 A_i 를 계산할 때 데이터의 개수가 부족할 경우 행렬이 0이 될 수 있어서 수식 (2.14)를 이용하여 최소 값을 제한한다.

$$(1 - \gamma)A_i + \gamma \det(A_i)^{\frac{1}{N}} I \rightarrow A_i \quad (2.14)$$

여기서, A_i 는 전체 데이터를 이용하여 계산된 분산 행렬을 나타내며, I 는 단위 행렬, γ 는 가중치 상수를 나타낸다. 분산 행렬에서 고유 값(eigen value)과 고유 벡터(eigen vector)를 계산할 수 있다. 계산된 최대 고유 값을 이용하여 최소 고유 값을 제한하여 클러스터의 형태를 기하학적으로 유지될 수 있도록 한다.

제3장 정보 입자 생성 및 입자 모델 설계

제1절 입자 컴퓨팅 및 정보 입자

지능형 컴퓨팅 및 인간 중심 시스템 영역이 통합되고 일관된 정보 처리 방법으로 입자 컴퓨팅에 관한 연구들이 활발히 진행되고 있다. 입자 컴퓨팅은 의미 있는 정보 입자를 생성, 개발 및 처리에 중점을 두고 있으며 인간 중심의 지능 시스템의 분석 및 설계를 지원하는 방법이다. 입자 컴퓨팅은 다양한 형태(집합 이론, 간격 미적분, 러프(rough) 집합, 퍼지 집합, 음영(shadowed) 집합, 확률적 분포)의 정보 입자를 기반으로 광범위한 지식 체계를 구성 및 통합하여 일관된 방법론 및 환경을 형성하는 방법이다[31, 32]. 그림 3.1. 은 정보 입자의 형태를 나타내고 있다.

정보 입자(IG, Information Granules)는 복잡한 실세계의 정보를 표현하는 정보 처리의 새로운 방법으로서, Zadeh [53, 54]의 선구적인 연구에 뿌리를 두고 있다. 일반적으로 수치적 값에서 발생하여 유사성, 물리적 인접성, 일관성 등으로 인해 배열되는 집합이다. 이와 같은 정보 입자는 서로 다른 특징이 나타나는 데이터의 규칙성을 입자화하여 나타낸다. 예를 들어 저해상도 위성 이미지에서는 황사, 태풍과 같은 기상 현상을 나타내는 구름의 특징을 표현할 수 있지만, 고해상도 위성 이미지는 위와 같은 대기 현상을 파악할 수 없다. 하지만, 인구가 밀집한 대도시 거리와 같은 소규모의 특징을 파악할 수 있다. 데이터 처리에서도 마찬가지로 다양한 해상도 또는 입자화에서 서로 다른 특징과 각각의 관계를 표현할 수 있다. 입자 컴퓨팅은 더 효과적인 추론 시스템 설계 및 기계 학습을 할 수 있도록 도움을 준다.

데이터를 정보 입자화하는 다양한 방법들이 존재한다. 고전적인 방법으로는 주 성분 분석(PCA, Principal Component Analysis), 요인 분석(factor analysis), 다차원 스케일링(multidimensional scaling) 등이 있다. 위 방법들은 원본 데이터를 선형 또는 비선형 변환을 이용하여 통계적 관계를 표현한다. 정보 입자화하는 다양한 방법들은 고전적인 방법보다 클러스터링 방법들을 기반으로 둔다. 클러스터링을 통해 생성된 클러스터는 원본 데이터의 특징을 표현할 수 있으며 전체 데이터에서 필요한 정보를 이용하여 새로운 데이터를 생성할 수 있다. 정보 입자는 생

성하는 방법(고전적 방법, 클러스터링)에 따라 다양한 형태로 나타날 수 있다. 일반적으로 퍼지 클러스터링을 이용해 정보 입자를 생성한다. 이처럼 정보 입자는 관심 영역에서 필요한 부분을 추상화하고 고려하기 위해 다양한 방법을 이용해 원본 데이터를 입자화하여 실세계의 여러 응용 분야를 인식하는 인간의 사고방식을 표현할 수 있다. 따라서, 입자 컴퓨팅 및 정보 입자는 인간의 문제 해결에 필수적이며 지능형 추론 시스템 설계에 매우 큰 영향을 미친다.

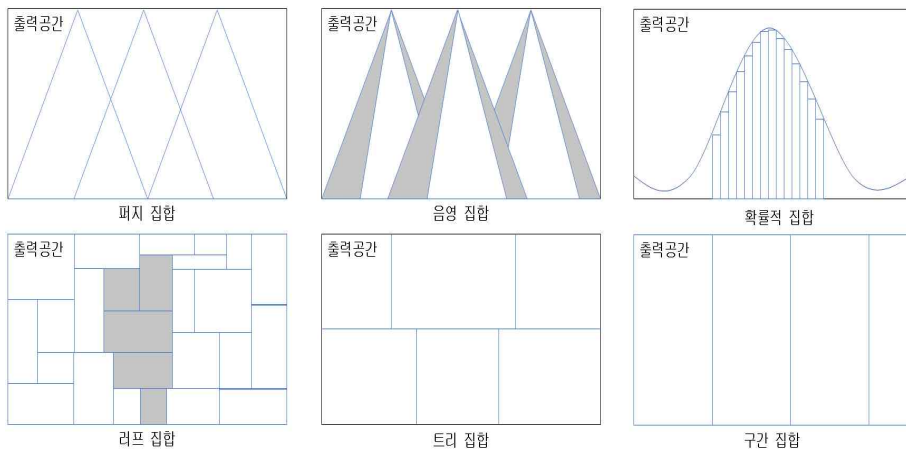



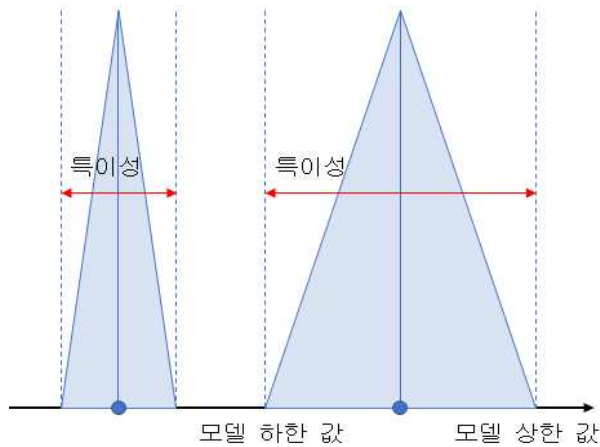
그림 3.1. 정보 입자의 형태

제2절 합리적인 정보 입자 생성

입자 컴퓨팅에서 컴퓨팅 및 추론은 숫자 중심이 아닌 기본적인 개념 및 알고리즘으로 간주되는 정보 입자를 중심으로 이루어진다. 정보 입자는 지식 표현 및 처리의 중요한 역할을 함으로써 입자 컴퓨팅의 핵심 요소이다[55-57]. 다양한 클러스터링을 이용하여 생성된 정보 입자는 다소 제한적이기는 하지만 일부 원본 데이터의 일반적인 구조를 반영할 수 있다. 숫자 중심으로 이루어진 원본 데이터는 데이터의 특징과 연관성을 나타낼 수 없지만, 정보 입자는 이를 가능하게 한다. 합리적인 정보 입자 생성은 원본 데이터를 이용하여 의미 있는 정보 입자를 생성하는 데 중점을 둔다. 합리적인 정보 입자 생성을 위해 정보 입자의 범위성(coverage)과 특이성(specificity) 두 가지 요구 사항이 충족되어야 한다. 그림 3.2. 는 정보 입자의 범위성과 특이성을 나타낸다.



(a) 정보 입자의 범위성의 개념



(b) 정보 입자의 특이성의 개념

그림 3.2. 합리적인 정보 입자 생성을 위한 범위성 및 특이성의 개념

범위성은 형성된 정보 입자에 목표가 되는 데이터가 포함되는지를 나타낸다. 다시 말해 정보 입자의 범위 내에 목표가 되는 전체 데이터가 얼마나 축적되는지 축적된 정도를 표현한다. 정보 입자에 축적되는 데이터가 많을수록 범위성은 높은 값을 갖고 정보 입자의 적법성(legitimacy)을 증명할 수 있으므로 모델링 기능과 관련하여 더 나은 모델이 될 수 있다. 포함 정도를 나타내는 *incl*는 정보 입자 Y_k 가 생성된 형태에 따라 지정된다. Y_k 가 컨텍스트 형태일 때 *incl*는 $Y_k = [y_k^-, y_k^+]$ 에 y_k 가

포함되어 있으면 1에 가까운 값을 갖게 되고 포함되어 있지 않으면 0에 가까운 값을 갖는다. 다시 말해 범위성을 사용하여 입자 모델의 입자화된 출력에 데이터 y_k 가 포함된 수를 계산하고 모든 데이터에 대해 계산된 평균값을 계산할 수 있다. 이상적인 상황은 범위성이 1에 가까운 값을 갖게 되는 것으로 모든 데이터가 입자 모델의 출력에 포함되는 것이다.

$$Coverage = \frac{1}{N} \sum_{k=1}^N incl(y_k, Y_k) \quad (3.1)$$

특이성은 각각의 정보 입자 y_k 가 얼마나 구체적이고 의미론적으로 설명 가능한지를 나타낸다. 일반적으로 임의의 정보 입자 Y_k 의 특이성은 수식 (3.2)을 만족해야 한다. 다시 말해 정보 입자가 가능한 한 상세하게 생성되어야 하며 각각의 정보 입자에 설명이 가능한 의미(meaning)가 있어야 한다. 정보 입자가 컨텍스트 형태일 때 간격, 즉 상한값과 하한값 사이가 좁을수록 특이성은 높은 값을 갖는다. 정보 입자 Y_k 가 점 형태로 감소하게 되면 특이성은 1에 가까운 값에 도달하게 된다.

$$if Y_k \subset Y'_k \text{ then } specificity(Y_k) > specificity(Y'_k), \text{ and } specificity(\{y\}) = 1 \quad (3.2)$$

$$Specificity = \frac{1}{N} \sum_{k=1}^N \exp(-|y_k^+ - y_k^-|) \quad (3.3)$$

수식 (3.3)에서 사용한 지수함수 대신 구간 길이의 연속 감소함수를 고려할 수 있다. 범위성과 특이성을 이용하여 정보 입자의 타당성과 입자 모델의 예측 성능을 평가할 수 있다. 다시 말해 정보 입자의 범위성과 특이성을 고려하여 입자 모델을 평가할 수 있으며 범위성과 특이성을 동시에 극대화하는 방법을 모색해야 한다. 이 두 가지 특성은 상충(trade off) 관계이다. 범위성이 높은 값을 가질수록 특이성은 낮은 값을 갖는 것을 의미한다. 합리적인 정보 입자는 수식 (3.4)와 같이 나타낼 수 있으며 이를 성능지표(PI, Performance Index)라고 한다.

성능지표는 모델의 정확성과 명확성을 평가하는 데 중요한 역할을 하며, 모델의 성능을 평가하는 방법들이 다양하게 개발되어왔다. 일반적인 성능 평가 방법에

는 평균제곱근오차(RMSE, Root Mean Square Error)와 평균절대백분율오차(MAPE, Mean Absolute Percentage Error) 등이 있다. 평균제곱근오차는 실제 예측 값에서 모델 예측 값을 빼고 제공의 평균을 계산한 다음, 그 값을 제곱하여 성능을 평가한다. 평균절대백분율오차는 실제 출력 값에서 모델 예측 값을 뺀 다음, 모델 예측 값으로 나누어 성능을 평가한다. 이와 같은 성능 평가 방법은 모델의 출력 값이 수치적인 값일 때 주로 사용된다. 그러나, 정보 입자로 구성된 입자 모델의 경우 모델 출력 값이 수치적인 값이 아닌 정보 입자이기 때문에 일반적인 성능 평가 방법을 사용하여 모델을 평가하는데 어려움이 존재한다. 이를 해결하기 위해 입자 모델을 위한 성능 평가 방법으로 범위성과 특이성에 관한 연구가 활발히 진행되었다[58-63]. 성능지표는 높은 값을 갖을수록 의미 있는 정보 입자이며 우수한 성능을 갖는 입자 모델을 설계할 수 있다.

$$Performance\ index = coverage(\epsilon) \cdot specificity(\epsilon) \quad (3.4)$$

입자 모델로부터 얻어진 성능지표 값을 이용하여 범위성 및 특이성의 관계를 좌표로 나타낼 수 있으며 성능지표 값의 변화에 대한 모델 성능의 변화를 관찰할 수 있다. 그림 3.3. 은 범위성과 특이성의 상충 관계를 나타낸다. 범위성이 0에 가까운 값을 가질 경우 특이성은 1에 가까운 값을 갖게 되며 정보 입자의 형태는 점에 가깝게 된다. 범위성이 증가할 경우 정보 입자의 크기가 증가하지만, 특이성이 감소하는 것을 확인할 수 있다.




그림 3.3. 정보 입자의 범위성과 특이성의 상충 관계

제3절 퍼지 입자 모델

실세계의 여러 응용 분야에서 사용되는 퍼지 규칙 기반 추론 시스템의 추론 값은 수치적인(numeric) 값으로 나타나기 때문에 결과를 언어적으로 설명하는 데 한계가 있다. 퍼지 클러스터링을 이용해 생성된 정보 입자로 설계된 퍼지 입자 모델은 출력 값이 정보 입자이기 때문에 지식 표현 및 처리할 수 있다. 퍼지 입자 모델은 A 에 포함된 데이터에 사전 결정된 수준의 정보들을 입자화하여 구성된다. 데이터의 입자화 특성으로 인해 수치적인 입력 및 출력을 갖는 기존의 퍼지 모델의 변수들을 입자화된 출력으로 생성된다. 정보 입자의 3장 2절에서 설명한 합리적인 정보 입자 생성 방법에 기반을 둔다. 퍼지 입자 모델에서 사용되는 정보 입자는 퍼지 집합의 형태를 나타낸다. 정보 입자의 입자화 수준이 $\epsilon(\epsilon \in [0, 1])$ 이라고 가정한다. 입자화 수준은 각 규칙의 출력공간에 있는 데이터인 $a_{i_0}, a_{i_1}, a_{i_2}, \dots, a_{i_N}$ 에 의해 다음과 같이 설명할 수 있는 임의의 수준 $\epsilon(\epsilon \in [0, 1])$ 의 정보 입자를 허용하여 퍼지 집합 형태의 정보 입자 a_{i_0} 를 생성한다.

$$G(a_{i_0}) = \left[\min(a_{i_0}(1 - \epsilon), a_{i_0}(1 + \epsilon)), \max(a_{i_0}(1 - \epsilon), a_{i_0}(1 + \epsilon)) \right] = \quad (3.4) \\
 \left[a_{i_0}^+, a_{i_0}^- \right] = A_{i_0}$$

동일한 방법으로 출력공간에 있는 데이터인 $a_{i_1}, a_{i_2}, \dots, a_{i_N}$ 을 입자화하여 정보 입

자 $A_{i1}, A_{i2}, \dots, A_{iN}$ 를 생성한다. 일반적인 퍼지 입자 모델은 출력공간을 균등하게 분할하여 삼각형 형태의 컨텍스트를 생성하고 각각의 컨텍스트에서 클러스터가 생성된다. 퍼지 입자 모델의 출력 값인 y 는 컨텍스트 형태로 나타나며 입력 x_k 에 대해 각각의 퍼지 규칙은 다음과 같은 정보 입자 출력을 생성한다.

$$\text{if } x_k \in \Omega_i, \text{ then } Y_{ik} = f_i(x_k, A_i) = A_{i0} \oplus A_{i1} \otimes x_{k1} \oplus A_{i2} \otimes x_{k2} \oplus \dots \oplus A_{iN} \otimes x_{kN} \quad (3.5)$$

모든 퍼지 규칙에 기초하여 생성된 컨텍스트 형태의 정보 입자 출력인 Y_k 는 다음과 같은 방법으로 계산된다.

$$Y_k = \sum_{i=1}^c \Omega_i(x_k) \oplus Y_k \quad (3.6)$$

여기서, \oplus, \otimes 는 각각의 정보 입자에 대해 완료된 덧셈 및 곱셈 연산을 나타낸다. 그림 3.4. 은 퍼지 입자 모델의 구조를 나타낸다.




그림 3.4. 퍼지 입자 모델의 구조

제4절 컨텍스트 기반 GK 클러스터링(CGK)

출력공간을 고려한 클러스터링 방법인 컨텍스트 기반 GK 클러스터링은 기존의 GK 클러스터링에서 출력공간을 고려하여 입력 및 출력공간에 있는 데이터의 상관 관계를 기반으로 클러스터를 생성하는 방법이다. 두 개의 특징을 가지고 있는 데이터가 있다고 가정한다. 위 데이터는 종속변수에 의해 빨간색과 파란색으로 나타낼 수 있다. 그림 3.5. 는 두 개의 특징을 가지고 있는 데이터를 나타낸다.



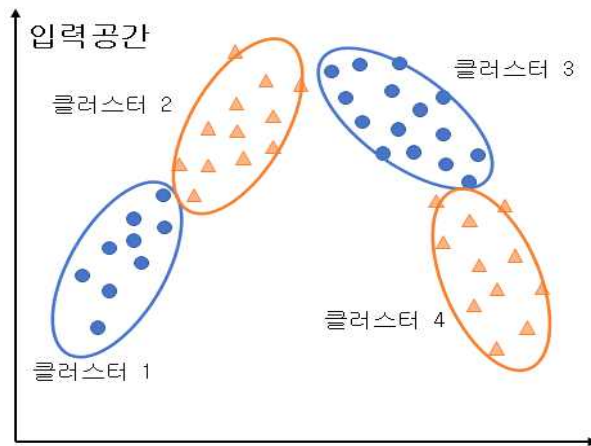


그림 3.5. 출력공간에서 두 개의 특징을 가지고 있는 데이터집합

그림 3.6. (a)는 일반적인 GK 클러스터링을 통해 생성된 클러스터를 보여준다. 그림 3.6.(a)에서 보이는 바와 같이 입력공간에 있는 데이터의 특징을 고려해서 클러스터를 생성했지만, 출력공간의 특징을 고려하지 못한 것을 확인할 수 있다. 그림 3.6. (b)는 출력공간을 고려한 컨텍스트 기반 GK 클러스터링을 통해 생성된 클러스터를 보여준다. 그림에서 보이는 바와 같이 입력공간뿐만 아니라 출력공간 까지 고려하여 클러스터를 생성하기 때문에 출력공간에 있는 데이터의 특징을 보존할 수 있어서 일반적인 GK 클러스터링보다 효율적으로 클러스터를 생성할 수 있다. 그림 3.7. 은 출력공간을 고려한 컨텍스트 기반 GK 클러스터링의 개념도를 나타낸다.

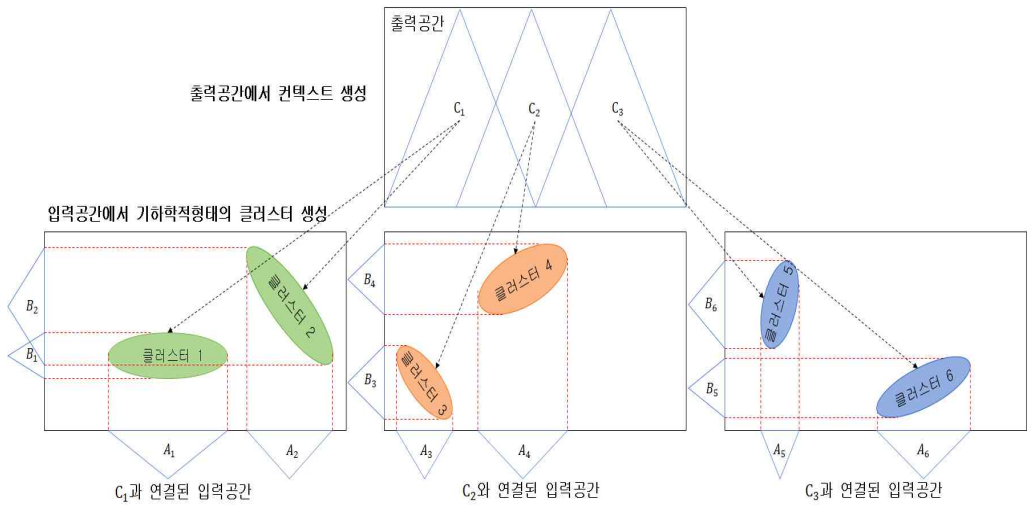


(a) GK 클러스터링에서 생성된 클러스터



(b) 컨텍스트 기반 GK 클러스터링에서 생성된 클러스터

그림 3.6. GK 클러스터링과 컨텍스트 기반 GK 클러스터링에서 생성된 클러스터 비교



컨텍스트와 클러스터를 이용하여 자동으로 규칙 생성

IF $X = A_1$ AND $Y = B_1$, THEN $Z = C_1$
 IF $X = A_2$ AND $Y = B_2$, THEN $Z = C_1$

IF $X = A_3$ AND $Y = B_3$, THEN $Z = C_2$
 IF $X = A_4$ AND $Y = B_4$, THEN $Z = C_2$

IF $X = A_5$ AND $Y = B_5$, THEN $Z = C_3$
 IF $X = A_6$ AND $Y = B_6$, THEN $Z = C_3$

그림 3.7. 컨텍스트 기반 GK 클러스터링의 개념

출력공간에 있는 데이터에 대한 컨텍스트는 수식 (3.7) 과 같이 나타낼 수 있다. 여기서, d 는 출력공간에 있는 데이터를 나타낸다. 출력공간에 있는 임의의 데이터에 대해 컨텍스트 형태의 정보 입자를 이용할 수 있다고 가정할 때, $f_k = T(d_k)$ 는 출력공간에 생성된 컨텍스트가 k 번째 데이터의 소속된 정도를 나타낸다.

$$D: T \rightarrow [0, 1] \quad (3.7)$$

유클리디안 거리를 이용하여 클러스터를 생성하는 퍼지 클러스터링을 개선한 GK 클러스터링은 수식 (3.8) 을 이용하여 마할라노비스 거리로 클러스터를 생성한다.

$$d_{GK}^2(x_k, v_i) = \|x_k - v_i\|_{A_i}^2 = (x_k - v_i)^T A_i (x_k - v_i) \quad (3.8)$$

여기서, A_i 는 각 i 에 대한 고정 상수인 $\det(A_i) = \rho_i$ 를 갖는 행렬을 나타낸다. 퍼지 클러스터링은 유클리디안 거리를 이용하기 때문에 원형 형태의 클러스터를 생성하는 문제에서만 우수한 성능을 보인다. 이러한 단점을 보완하기 위해 GK 클러스터링은 다양한 기하학적 형태의 클러스터를 생성할 수 있도록 $d_{GK}^2(x_k, v_i)$ 를 이용하여 퍼지 클러스터링의 유클리디안 거리를 확장하고 거리 표준이 국부적인 부분에도 적용할 수 있도록 한다. 목적 함수는 수식 (3.9), (3.10), (3.11) 와 같이 나타낸다.

$$J_m^{GK}(\mu, v) = \sum_{k=1}^n \sum_{i=1}^c \mu_{ik}^m d_{GK}^2(x_k, v_i) \quad (3.9)$$

$$v_i = \frac{\sum_{k=1}^n \mu_{ik}^m x_k}{\sum_{k=1}^n \mu_{ik}^m} \quad (3.10)$$

$$\mu_{ik} = \frac{\|x_k - v_i\|_{A_i}^{-\frac{2}{m-1}}}{\sum_{j=1}^c \|x_k - v_j\|_{A_j}^{-\frac{2}{m-1}}} \quad (3.11)$$

출력공간에 생성된 각각의 컨텍스트에서 수식 (3.9), (3.10), (3.11)을 반복하여 기하학적 형태의 클러스터를 생성한다. 컨텍스트 기반 GK 클러스터링의 진행 순서는 다음과 같다.

[단계 1] 언어적으로 표현할 수 있는 컨텍스트의 수와 각각의 컨텍스트에서 생성되는 클러스터의 수를 선택하고 ϵ 을 선택한다. 여기서, ϵ 는 기하학적 형태의 정도를 설정하는 것으로 0보다 큰 값을 선택해야 한다. 소속행렬 v 를 0과 1 사이의 값으로 초기화한다. 컨텍스트와 클러스터의 수는 동일하게 설정할 수 있으며, 서로 다른 값으로 설정할 수 있다.

[단계 2] 출력공간을 균등하게 분할하여 일정한 크기의 컨텍스트 형태의 정보 입

자를 생성할 수 있으며 가우시안 확률 분포를 이용하여 서로 다른 크기의 컨텍스트 형태의 정보 입자를 생성할 수 있다.

[단계 3] 수식 (3.10)을 이용하여 출력공간에 있는 컨텍스트에서 클러스터의 중심과 소속 행렬을 계산한다.

[단계 4] 수식 (3.9)와 수식 (3.12)를 이용하여 목적 함수를 계산하고 계산된 값이 이전 목적 함수 값보다 큰 경우 위 과정을 반복한다. 반대로 계산된 값이 이전 목적 함수 값보다 작은 경우 위 과정을 멈춘다.

$$\|\mu^t - \mu^{t-1}\| \leq \epsilon \quad (3.12)$$

제5절 CGK 기반 입자 모델 설계

GK 입자 모델은 출력공간을 고려한 컨텍스트 기반 GK 클러스터링을 이용하여 출력공간에 컨텍스트 형태의 정보 입자를 생성하고 각각의 컨텍스트에서 기하학적 형태의 클러스터를 생성하여 설계된다. 그림 3.8. 은 출력공간에서 컨텍스트가 3개 생성되고 각각의 컨텍스트에서 클러스터가 3개 생성되는 GK 입자 모델의 구조를 나타낸다. 그림과 같이 전제부 변수와 결론부 변수가 존재한다. 결론부 변수는 출력공간에 생성된 컨텍스트 형태의 정보 입자를 나타내며, 전제부 변수는 각각의 컨텍스트에서 생성된 클러스터의 중심 즉 입력공간에 생성된 정보 입자를 나타낸다. 출력공간에 생성되는 컨텍스트는 앞에서 설명했던 것과 같이 균등하게 생성하는 방법과 유연하게 생성하는 방법을 이용할 수 있다. GK 입자 모델의 최종 출력 값 Y 는 수식 (3.13)을 이용해 계산된다.

$$Y = \sum_{\oplus} W_i \otimes z_i \quad (3.13)$$

여기서, 덧셈 및 곱셈 기호인 \oplus, \otimes 는 각각의 정보 입자에 대해 완료된 덧셈 및 곱셈 연산을 나타낸다. GK 입자 모델 전제부를 처리하는 과정에서 퍼지 집합이 생성된다. 이때, 컨텍스트 기반 GK 클러스터링에 의해 생성된 클러스터는 GK 입자

모델의 은닉 계층으로 나타낼 수 있다. 은닉 계층과 출력 계층 사이는 언어적으로 설명 가능한 컨텍스트로 표현된다. 전체 컨텍스트를 이용하여 GK 입자 모델의 최종 출력인 합계 값을 수식 (3.14)와 같이 표현할 수 있다.

$$Y = (z_{11} \otimes A_1 \oplus z_{12} \otimes A_1 \oplus \dots \oplus z_{1n1} \otimes A_1) \oplus (z_{21} \otimes A_2 \oplus z_{22} \otimes A_2 \oplus \dots \oplus z_{2n2} \otimes A_2) \oplus \dots \quad (3.14)$$

$$(z_{c1} \otimes A_c \oplus z_{c2} \otimes A_c \oplus \dots \oplus z_{cnc} \otimes A_c)$$

GK 입자 모델의 최종 출력은 삼각형 형태의 컨텍스트로 표현되며 퍼지 집합으로 표현하면 다음과 같이 나타낼 수 있다.

$$Y_i = (y_i^-, y_i, y_i^+) \quad (3.15)$$

여기서, y_i^-, y_i, y_i^+ 는 GK 입자 모델의 하한 값, 모델 값, 상한 값을 나타내며, 삼각형 형태의 컨텍스트의 각각의 점을 의미한다. 하한 값, 모델 값, 그리고 상한 값은 수식 (3.16), (3.17), (3.18)으로 나타낼 수 있다.

$$y_i^- = (z_{11}a_1 + z_{12}a_1^- + \dots + z_{1n1}a_1^-) + \dots (z_{c1}a_c^- + z_{c2}a_c^- + \dots + z_{cnc}a_c^-) \quad (3.16)$$

$$y_i = (z_{11}a_1 + z_{12}a_1 + \dots + z_{1n1}a_1) + \dots (z_{c1}a_c + z_{c2}a_c + \dots + z_{cnc}a_c) \quad (3.17)$$

$$y_i^+ = (z_{11}a_1 + z_{12}a_1^+ + \dots + z_{1n1}a_1^+) + \dots (z_{c1}a_c^+ + z_{c2}a_c^+ + \dots + z_{cnc}a_c^+) \quad (3.18)$$

컨텍스트 기반 GK 클러스터링을 수행할 때 소속 행렬 u 는 0과 1 사이의 값으로 나타낼 수 있으며 소속 행렬의 요구 사항을 다음과 같이 나타낼 수 있다.

$$U(f) = \left\{ \begin{array}{l} u_{ik} \in [0, 1] \mid \sum_{i=1}^c u_{ik} = f_k \quad \forall k \\ \text{and } 0 < \sum_{k=1}^N u_{ik} < N \end{array} \right\} \quad (3.19)$$

여기서, 컨텍스트는 출력공간을 퍼지 집합 형태로 균등하게 분할하거나 유연하

게 분할하여 생성된다. GK 입자 모델의 구조는 다음과 같다. 입력 계층은 데이터를 받아 GK 입자 모델에 들어가는 과정이다. 활성화 계층은 출력공간에서 생성된 컨텍스트에 해당하는 입력공간에서 클러스터를 생성하는 과정으로 클러스터 활성화 단계이다. 전제부 계층은 각각의 컨텍스트에서 조건부 클러스터링이 진행된다. 활성화 계층과 전제부 계층은 연결이 되어 있으며, 컨텍스트가 주어질 때 GK 클러스터링에서 데이터 정보를 활용한다. GK 입자 모델은 활성화 계층과 전제부 계층에 중점을 둔다. 컨텍스트는 전제부에 있는 GK 클러스터링과 연결되어 있으며 입력공간에서 데이터의 특징을 고려하여 퍼지 집합을 생성한다. 각각의 컨텍스트에서 지정된 수만큼의 클러스터를 생성하며 출력 계층에서 합계되는 노드의 수는 컨텍스트의 수와 같다. 출력 계층에서 합계된 최종 출력 값은 삼각형 형태의 컨텍스트로 표현된다.




그림 3.8. CGK 입자 모델의 구조

제4장 계층적 구조의 입자 모델 설계

제1절 계층적 구조의 CGK 기반 입자 모델 설계

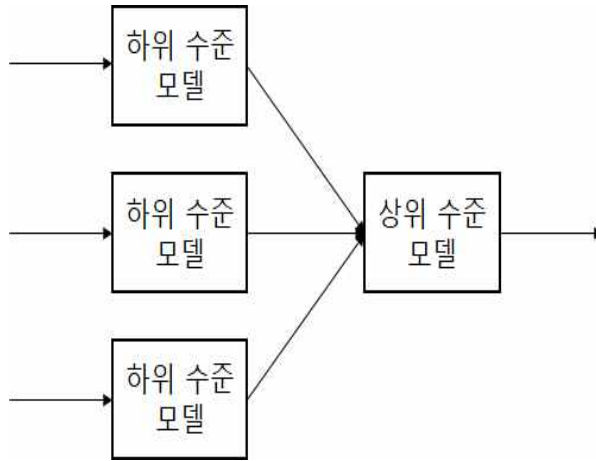
퍼지 시스템 및 입자 모델에 대한 입력변수의 수가 증가함에 따라 규칙의 수는 기하급수적으로 증가하게 된다. 대규모 규칙 기반은 퍼지 시스템 및 입자 모델의 계산 효율성을 감소시키는 문제가 발생한다. 또한 입자 모델의 작동을 이해하기 어렵게 만들고 규칙과 소속함수를 조정하기 어려워진다. 다양한 예측 관련 응용 분야에는 제한된 양의 데이터를 가지고 있으므로 대규모 규칙 기반의 퍼지 시스템 및 입자 모델의 일반화 가능성을 감소시킨다. 이러한 문제를 해결하기 위해 단일 퍼지 시스템 및 단일 입자 모델이 아닌 상호 연결된 구조인 계층적 구조의 입자 모델을 설계할 수 있다. 입자 모델이 계층적 트리(tree) 구조로 배열되기 때문에 트리를 계층적 구조라고도 한다. 계층적 구조에서 낮은 수준의 입자 모델의 출력은 높은 수준의 입자 모델에 대한 입력으로 사용된다. 계층적 구조의 입자 모델은 동일한 수의 입력을 가진 단일 입자 모델보다 계산적으로 더 효율적이고 이해하기 쉬운 구조로 설계된다[64-66].

다양한 예측 관련 응용 분야에 사용할 수 있는 계층적 구조로는 점증형(incremental) 구조, 집계형(aggreated) 구조, 계단형(cascaded) 구조가 있다. 그림 4.1. 은 각각의 계층적 구조의 유형을 나타내고 있다. 점증형 구조는 입력변수가 여러 단계에서 통합되어 여러 수준에서 출력 값을 계산한다. 그림 4.1. (a) 과 같이 입자 모델 GM_i^n 이 3단계로 구축되어 있다. 여기서, i 는 n 번째 수준의 입자 모델을 나타낸다. 점증형 입자 모델에서 i 가 1일 때 이는 각 수준에 하나의 퍼지 추론 시스템이 있음을 의미한다. n 번째 수준의 i 번째 입자 모델의 j 번째 입력은 x_{ij}^n 이라고 나타내며, n 번째 수준의 i 번째 입자 모델의 k 번째 출력은 y_{ik}^n 으로 나타낸다. 점증형 입자 모델의 각각의 수준에서 입력변수를 선택할 때 최종 출력 값에 대한 기여도에 따라 입력변수 순위를 지정한다. 가장 높은 기여도를 갖는 입력변수는 일반적으로 가장 낮은 수준에서 사용되는 반면 기여도가 가장 낮은 입력변수는 가장 높은 수준에서 사용한다. 다시 말해 낮은 순위의 입력 값은 높은 순위의 입력 값에 종속된다.

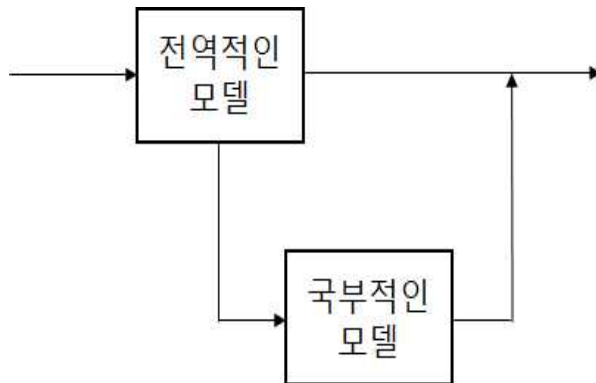
집계형 구조는 원본 데이터의 입력변수들이 가장 낮은 수준에서 사용되고 각

입력변수를 입력받은 하위 수준의 입자 모델의 출력은 상위 수준의 입자 모델에 입력되어 결과가 결합하는 구조이다. 예를 들어, 그림 4.1. (b) 와 같이 입자 모델 GM_n^m 이 2단계로 구축되어 있다. i_n 은 n 번째 수준에서 입자 모델의 지수를 나타낸다. 집계형 입자 모델에서 입력변수는 특정 의사결정을 위해 그룹화된다. 예를 들어, 자율 로봇 탐색 작업을 장애물에 충돌하지 않으면서 탐색하는 것과 목표에 도달하는 두 개의 작업이 결합한다. 탐색 작업을 수행하기 위해 입자 모델은 장애물과 관련된 입력변수를 사용하게 된다. 목표에 도달하는 작업을 수행하기 위해서는 로봇의 현재 위치와 진행 방향에 관련된 입력변수를 사용한다. 집계형 입자 모델은 구조를 변형하여 하위 수준의 입자 모델의 출력을 직접 합산하여 최종 출력을 계산하는 병렬 집계형 입자 모델을 설계할 수 있다.

계단형 구조는 앞에서 설명한 점증형 구조와 집계형 구조를 결합한 구조로써 상관된 입력변수와 상관되지 않은 입력변수를 모두 포함하는 시스템에 적합하다. 상관된 입력변수를 집계형 구조로 그룹화하고 상관되지 않은 입력변수를 점증형 구조로 추가하는 형태를 나타낸다.



(a) 집계형 구조의 입자 모델



(b) 계단형 구조의 입자 모델

그림 4.1. 계층적 구조의 입자 모델

제2절 집계형 구조의 CGK 기반 입자 모델 설계

본 논문에서는 집계형 구조를 이용한 입자 모델을 설계한다. 집계형 구조를 구축할 때 하위 수준과 상위 수준에 입자 모델을 이용하지 않고 하위 수준을 선형회귀(LR, Linear Regression) 모델, 신경회로망(NN, Neural Network), 방사기저함수신경망(RBFN, Radial Basis Function Network)로 구성하여 각각의 예측 모델의 출력을 상위 수준인 퍼지 입자 모델의 입력으로 사용하여 최종 출력을 계산한다.

선형회귀 모델 [67]은 입력변수와 출력변수 간의 선형 상관 관계를 모델링하는

것으로 단순 선형회귀 모델을 설명변수를 기반으로 하고 다중 선형회귀 모델은 둘 이상의 설명변수를 기반으로 한다. 선형회귀 모델은 데이터에서 알려지지 않은 매개변수가 추정된다. 선형회귀 모델은 다음과 같이 나타낼 수 있다.

$$y_i = \beta_1 x_{i1} + \dots + \beta_p x_{ip} + \varepsilon_i = x_i^T \beta + \varepsilon_i, \quad i = 1, 2, \dots, n \quad (4.1)$$

여기서, β_i 는 각각의 독립변수의 계수를 나타내며, p 는 선형회귀 모델로 추정되는 모수의 개수를 나타낸다. r 는 전치를 의미하고 $x_i^T \beta$ 는 x_i 와 β 의 내적을 나타낸다. ε_i 는 오차항, 오차 변수를 나타내며 종속변수와 독립변수 사이에 오차를 의미한다.




그림 4.2. 선형회귀 모델의 개념

신경회로망 [68]은 인지과학과 기계 학습에서 생물학의 신경망에서 영감을 받아 만들어진 알고리즘으로 시냅스의 결합으로 신경망을 구축한 노드가 학습을 통해 시냅스의 결합 강도를 변화시켜 문제를 해결하는 능력을 갖추는 모델을 의미한다. 그림 4.3. 은 간단한 신경회로망의 구조를 나타내고 있다. 간단한 신경회로망은 입력 계층, 은닉 계층, 출력 계층으로 구성된다. 입력 계층은 데이터의 입력변수를 신경망에 입력하는 계층으로서 입력변수의 수와 입력 계층의 노드의 수는 같아야 한다. 일반적으로 입력 계층에서는 어떠한 계산도 수행되지 않으며 그냥 값을 전달하는 역할을 수행한다. 은닉 계층은 입력 계층과 출력 계층 사이에 있는

계층으로 둘 이상의 은닉 계층으로 구성되며 다층 신경망이라고 불린다. 출력 계층은 신경망의 출력을 계산하는 계층으로 해결하고자 하는 문제에 맞는 활성화 함수(activation function)를 이용하여 출력 값을 계산한다.




그림 4.3. 신경회로망의 구조

방사기저함수 신경망 [69]은 일반적인 신경망의 구조에서 활성화 함수를 시그모이드 함수가 아닌 방사기저함수를 이용하는 신경회로망이다. 그림 4.4. 는 방사기저함수 신경망의 구조를 나타내고 있다. 방사기저함수 신경망은 은닉 계층이 하나로써 단순한 구조로 이루어져 있으며 출력의 형태가 선형적이기 때문에 가중치 계산을 효율적으로 할 수 있다.

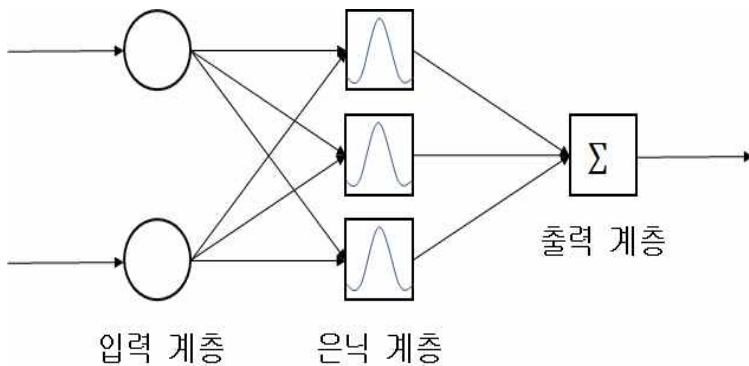


그림 4.4. 방사기저함수 신경망의 구조

선형회귀 모델, 신경회로망, 방사기저함수 신경망에서 나온 출력을 결합하여 상위 수준인 퍼지 입자 모델에 입력으로 사용하게 된다. 상위 수준의 퍼지 입자 모델에서는 출력공간에 생성되는 컨텍스트의 수와 입력공간에 생성되는 클러스터의 수를 지정하여 정보 입자를 생성하고 이를 바탕으로 계층적 구조의 최종 출력을 계산한다. 기존의 퍼지 입자 모델은 대규모 데이터를 처리할 때 입력 및 출력 공간에서 의미 있는 정보 입자를 생성하는 데 어려움이 있으며 계산시간이 오래 걸린다는 문제가 있다. 반면에, 본 논문에서 제안하는 계층적 구조의 퍼지 입자 모델은 하위 수준의 선형회귀 모델, 신경회로망, 방사기저함수 신경망에서 나온 출력을 결합하여 생성된 데이터를 상위 수준의 퍼지 입자 모델의 입력으로 사용할 때 대규모 데이터에서 의미 있는 정보 입자를 생성할 수 있으며 처리 시간을 단축할 수 있는 장점이 있다. 여기서, 입자 모델에서 사용하는 클러스터링이 컨텍스트 기반 퍼지 클러스터링일 경우 계층적 구조의 퍼지 입자 모델이 되며, 컨텍스트 기반 GK 클러스터링일 경우 계층적 구조의 GK 입자 모델이 설계된다. 그림 4.5. 는 계층적 구조의 입자 모델의 구조를 나타낸다.

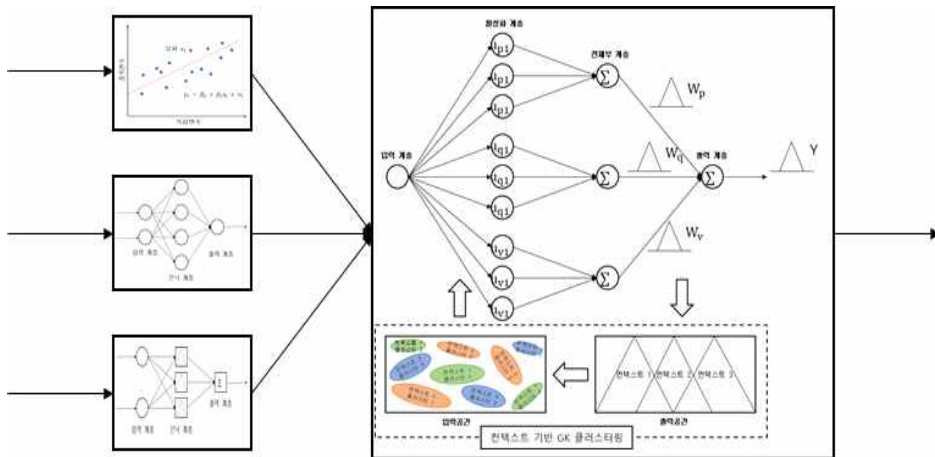


그림 4.5. 집계형 구조의 입자 모델의 구조

제5장 정보 입자 할당을 통한 최적화된 계층적 입자 모델

제1절 정보 입자의 최적 할당(allocation)

수치적인 원본 데이터를 클러스터링을 이용하여 정보 입자를 생성하고, 생성된 정보 입자들로 입자 모델을 설계한다. 입자 모델을 설계할 때 다음 조건을 만족해야 한다. 첫 번째 출력공간에 있는 데이터를 입자화한다. 두 번째 출력공간에서 생성된 각각의 정보 입자에 해당하는 입력공간에 있는 데이터를 입자화한다. 입력공간에서 클러스터링을 통해 생성된 클러스터의 중심을 입자화하는 것이다. 입자 모델을 설계할 때 고려할 사항은 다음과 같다. 모델이 입자화되도록 정보 입자 생성 방법이 제공되며, 정보 입자는 사용자가 지정한 형태로 제한된다. 정보 입자가 높은 값일수록 더 많은 설계 유연성을 갖게 된다. 반면에 정보 입자가 0인 경우 입자화되지 않고 원래 수치적인 값을 갖는 모델이 된다. 위와 같이 정보 입자화를 통해 정보 입자가 생성되는 두 가지 일반적인 방법으로 균등하게 생성하는 방법과 유연하게 생성하는 방법이 있다. 그림 5.1. 은 정보 입자화 방법을 통해 원본 데이터를 정보 입자화한 것을 나타낸다.

균등하게 생성된 정보 입자는 출력공간에 있는 데이터를 정보 입자화 수준에 맞게 대칭적이고 균일하게 정보 입자를 생성한 것으로 N 개의 정보 입자가 모두 같은 형태를 나타낸다. 수식 (5.1) 과 (5.2) 의 ϵ_0 은 $\frac{\epsilon}{2N}$ 을 나타낼 수 있으며 아래와 같이 균등하게 생성된 정보 입자의 상한값과 하한값을 나타낸다.

$$a_{ij}^- = \begin{cases} \min(a_{ij}(1 - \epsilon_0), a_{ij}(1 + \epsilon_0)) & \text{if } a_{ij} \neq 0 \\ -\epsilon_0 & \text{if } a_{ij} = 0 \end{cases} \quad (5.1)$$

$$a_{ij}^+ = \begin{cases} \max(a_{ij}(1 - \epsilon_0), a_{ij}(1 + \epsilon_0)) & \text{if } a_{ij} \neq 0 \\ \epsilon_0 & \text{if } a_{ij} = 0 \end{cases} \quad (5.2)$$

유연하게 생성된 정보 입자는 가우시안 확률 분포를 이용하여 출력공간에 있는 데이터의 분포를 기반으로 정보 입자를 생성한다. 각각의 정보 입자의 크기는 일정하지 않다.


$$a_{ij}^- = \begin{cases} \min(a_{ij}(1 - \varepsilon_{ij}^-), a_{ij}(1 + \varepsilon_{ij}^+)) & \text{if } a_{ij} \neq 0 \\ -\varepsilon_{ij}^- & \text{if } a_{ij} = 0 \end{cases} \quad (5.3)$$

$$a_{ij}^+ = \begin{cases} \max(a_{ij}(1 - \varepsilon_{ij}^-), a_{ij}(1 + \varepsilon_{ij}^+)) & \text{if } a_{ij} \neq 0 \\ \varepsilon_{ij}^+ & \text{if } a_{ij} = 0 \end{cases} \quad (5.4)$$


여기서, ε_{ij}^- 와 ε_{ij}^+ 는 다음 조건을 만족해야 한다.

$$0 \leq \varepsilon_{ij}^-, \varepsilon_{ij}^+ \leq 1 \quad (4.5)$$

$$\sum_{i=1}^c \left(\sum_{j=1}^n \varepsilon_{ij}^- + \sum_{j=1}^n \varepsilon_{ij}^+ \right) = \varepsilon \quad (4.6)$$



(a) 균등하게 생성된 정보 입자



(b) 유연하게 생성된 정보 입자

그림 5.1. 정보 입자화 방법을 통해 생성된 정보 입자의 형태

출력공간에 생성된 각각의 정보 입자에 해당하는 입력공간에서 정보 입자를 생성하는 방법은 클러스터링을 통해 생성된 클러스터의 중심 주변을 정보 입자화한다. 입력공간에서 정보 입자화는 $x_k \in D(G(x_k, V_1, V_2, \dots, V_c, U))$ 는 x 의 가능한 많은 데이터에 대해 만족해야 한다. 클러스터 중심을 입자화할 때 v_i 는 $[0, 1]$ 의 값을 가정하는 특정 수준의 입자화를 허용한다.

$$V_{ij} = [v_{ij} - \epsilon * range_j, v_{ij} + \epsilon * range_j] \quad (4.7)$$

여기서, i, j 는 클러스터의 수와 데이터의 수를 나타낸다. 클러스터 중심은 모든 데이터에 대해 동일한 수준으로 입자화된다. 클러스터 중심의 모든 좌표는 v_{ij} 주변에 대칭적으로 분포되고 부여된 입자화 수준에 의해 동등하게 영향을 받는다. 범위성 값이 높아질수록 성능지표 값이 높아진다. 성능지표는 범위성의 비감소 함수이다. 범위성이 너무 높으면 허용되지 않을 수 있으므로 일부 상한을 설정하고 범위성 자체를 다시 할당하여 효과적인 정보 입자를 생성할 수 있다.

일반적인 입자 모델은 클러스터 중심을 통해 정보 입자를 생성하는데 모든 변수에 동일한 범위성 값을 할당하여 모든 정보 입자를 동일한 방식으로 처리하는 한계를 보였다. 본 논문에서는 출력공간에 생성되는 정보 입자의 범위성과 입력공간에 생성되는 정보 입자의 수를 다시 할당하여 의미 있는 정보 입자를 생성하여 입자 모델의 예측 성능을 향상시킨다[70-72]. 그림 5.2. 는 출력공간에 생성되는 정보 입자의 변수를 다시 할당하여 합리적인 정보 입자를 생성하는 과정을 나타낸다. 그림과 같이 출력공간에 컨텍스트 형태의 정보 입자가 존재한다. 이때 하한값과 상한값이 존재하는데, 하한값과 상한값에 임의의 범위를 지정하고 최적화 알고리즘인 유전 알고리즘을 이용하여 정보 입자의 범위성과 특이성에 만족하는 값이 나오는 하한값과 상한값을 탐색한다.




그림 5.2. 합리적인 정보 입자 생성을 위한 출력공간에 생성되는 정보 입자의 변수 할당 과정

제2절 최적의 정보 입자를 통한 계층적 구조의 CGK 기반 입자 모델 설계

계층적 구조에서 집계형 구조의 CGK 기반 입자 모델은 일반적으로 사용되는 예측 모델인 선형회귀 모델, 신경회로망, 방사기저함수 신경망을 하위 모델로 사용하고 CGK 기반 입자 모델을 상위 모델로 사용한다. 수치적인 원본 데이터가 하위 모델에 입력되어 나오면 유형1 정보 입자가 된다. 하위 모델에서 계산된 출력을 결합한 유형1 정보 입자를 상위 모델에 입력하면 컨텍스트 기반 GK 클러스터링을 통해 유형2 정보 입자가 생성된다. 유형이 높아질수록 추상화 단계가 높아지기 때문에 언어적으로 설명 가능한 의미 있는 정보 입자를 나타낼 수 있다.

집계형 구조의 CGK 기반 입자 모델은 출력공간에서 컨텍스트 형태의 정보 입자를 생성하고 입력공간에서 기하학적 형태의 정보 입자를 생성한다. 본 논문에서는 집계형 구조의 CGK 기반 입자 모델의 출력공간에 생성된 컨텍스트 형태의 정보 입자를 생물 유전학에 기반을 둔 유전 알고리즘(GA, Genetic Algorithm)을 통해 최적 할당된다. 유전 알고리즘은 세대 수, 교차연산 비율, 돌연변이 비율 등을 설정하고 유전 연산자를 이용하여 새로운 집단을 만들어가며 최적화를 수행한다. 새로운 집단이 최적의 해를 갖는지를 확인하기 위해 적합도를 계산한다. 적합도는 세대가 생성된 후 학습데이터를 통해 얻어진 성능지표 값과 검증데이터를 통해 얻어진 성능지표 값을 이용하여 평가된다. 적합도는 생성된 해가 문제 해결에 얼마나 적합한지를 정량적으로 나타낼 수 있다. 유전 알고리즘의 진행 순서는 다음과 같다. 최적화할 컨텍스트의 하한 값과 상한 값을 이용하여 초기 염색체를 생성한다. 각각의 염색체들을 성능지표를 통해 적합한지 계산한다. 현재 염색체는 부모 염색체가 되고 이들로부터 교차 연산 및 돌연변이 연산을 통해 자손 염색체를 생성한다. 생성된 자손 염색체들의 적합도를 계산하고 만족스러운 값일 경우 위 과정을 종료하고 그렇지 않을 경우 다시 자손 염색체를 만들어 위 과정을 반복한다.

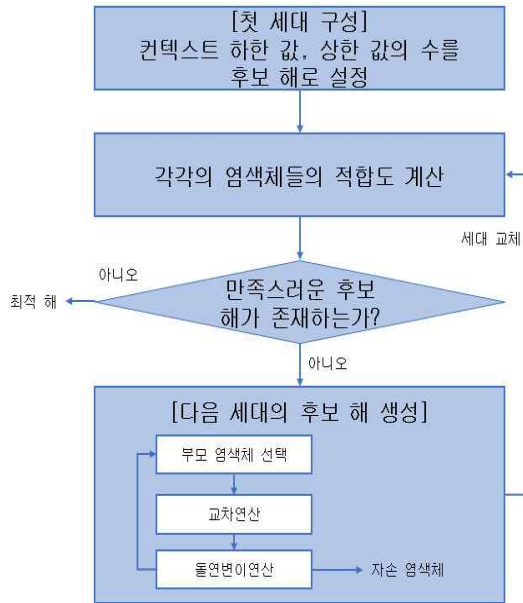


그림 5.3. 유전 알고리즘의 진행 순서

최적 할당된 출력공간의 정보 입자, 다시 말해 최적의 컨텍스트 형태의 정보 입자를 CGK 기반 입자 모델에 업데이트하여 출력공간에 있는 컨텍스트의 간격을 수정하고 수정된 각각의 컨텍스트와 연결된 입력공간에서 기하학적 형태의 정보 입자를 생성하여 입력공간 및 출력공간에서 최적의 정보 입자를 생성한다. 그림 5.4. 는 최적화된 CGK 기반 입자 모델의 구조를 보여주고 있으며, 그림 5.5. 는 최적화된 집계형 구조의 CGK 기반 입자 모델의 구조를 보여준다. 그림과 같이 컨텍스트 기반 GK 클러스터링을 통해 생성된 컨텍스트 형태의 정보 입자를 생성한다. 여기서, 유전 알고리즘을 이용해 컨텍스트의 하한 값과 상한 값을 최적화하여 컨텍스트를 업데이트하고 이를 통해 입력공간에서 최적화된 기하학적 형태의 정보 입자를 생성한다.




그림 5.4. 최적화된 CGK 기반 입자 모델의 구조




그림 5.5. 최적화된 집계형 구조의 CGK 기반 입자 모델의 구조

6장 실험 및 결과분석

본 논문에서 제안하는 방법인 CGK 기반 입자 모델(CGK-GM), 집계형 구조의 CGK 입자 모델(AGM)과 두 모델을 최적화한 최적화된 CGK 기반 입자 모델(optimized CGK-GM), 최적화된 집계형 구조의 CGK 기반 입자 모델(optimized AGM)의 타당성을 확인하기 위해 예측 분야에서 사용되는 벤치마킹 데이터베이스인 콘크리트 압축 강도 데이터베이스[73], 보스턴 주택 가격 데이터베이스[74], 그리고 정수장 응집제 투여량 데이터베이스[75]를 이용하여 실험을 진행했다. 실험 및 결과분석의 편의성을 고려하여 제안하는 4개의 입자 모델을 CGK-GM, AGM, optimized CGK-GM, optimized AGM으로 표기한다.

제 1절 데이터베이스

콘크리트 압축 강도 데이터베이스는 대만 청화대학교에서 수집된 데이터베이스로 인스턴스의 수는 1030, 변수의 수는 9로 구성되어 있다. 입력변수는 시멘트, 플라이 애쉬(fly ash), 고로 슬래그(blast furnace slag), 물, 가스제(superplasticizer), 굵은 골재, 미세 골재, 시간이며 출력변수는 콘크리트의 압축 강도이다.

보스턴 주택 가격 데이터베이스는 보스턴 시의 주택 가격에 대한 데이터베이스로서 주택의 가격 정보와 여러 요건들이 포함되어 있다. 인스턴스의 수는 506, 변수의 수는 14로 구성되어 있다. 입력변수는 자치 시 별 1인당 범죄율(CRIM), 25,000 평방피트를 초과하는 거주지역의 비율(ZN), 비소매상업지역이 점유하고 있는 토지의 비율(INDUS), 찰스강에 대한 더미변수(CHAS), 10ppm 당 농축 일산화질소(NOX), 주택 1가구당 평균 방의 개수(RM), 1940년 이전에 건축된 소유주택의 비율(AGE), 5개의 보스턴 직업센터까지의 접근성 지수(DIS), 방사형 도로까지의 접근성 지수(RAD), 10,000 달러당 재산세율(TAX), 자치 시 별 학생과 교사 비율(PTRATIO), 자치 시 별 유색인종(흑인)의 비율(B), 모집단의 하위계층의 비율(LSTAT)이며 출력변수는 본인 소유의 주택 가격(MEDV)이다.

정수장 응집제 투여량 데이터베이스는 하루에 1,320,000 톤의 물을 정수처리하는 서울시 암사 정수장에서 얻어진 데이터베이스로 인스턴스의 수는 346, 변수의

수는 6으로 구성되어 있다. 입력변수로는 원수의 탁도, 온도, pH, 알칼리성이며, 출력 변수는 응집제 종류 중 하나인 PAC의 투여량이다.

제 2절 실험 및 결과분석

본 논문에서는 일반적으로 사용되는 성능 평가 방법이 아닌 정보 입자 및 입자 모델에 적합한 성능 평가 방법인 성능지표 방법을 통해 입자 모델의 예측 성능을 평가한다. 3장 제2절의 수식 (3.4) 에서 설명한 것과 같이 성능지표는 정보 입자의 범위성과 특이성을 곱한 값으로 표현된다. 실험 방법은 다음과 같다. 각각의 데이터베이스를 학습데이터 50%, 검증데이터 50%로 나누고 0과 1 사이 값으로 정규화하여 실험해 사용했다. 기존의 GM과 제안하는 방법인 CGK-GM, AGM, optimized CGK-GM, optimized AGM의 컨텍스트(P)의 수와 클러스터(C)의 수를 2에서 6까지 1씩 증가하면서 실험을 진행하였으며, 퍼지화 계수는 2로 고정했다. 또한, 컨텍스트를 균등하게 생성하는 방법과 유연하게 생성하는 방법을 사용하여 실험을 진행했다. 컨텍스트 최적화를 위해 사용된 유전 알고리즘은 세대수를 50, 교차 연산 비율을 0.97, 돌연변이 비율은 0.01로 고정하여 Optimized CGK-GM과 optimized AGM에 사용했다.

다음은 콘크리트 압축 강도 예측 실험의 결과를 보여준다. 표 6-1. 은 컨텍스트를 균등하게 생성한 기존 GM의 예측 성능이며, 표 6-2. 는 컨텍스트를 유연하게 생성한 GM의 예측 성능이다. 그림 6.1. 은 기존 GM의 출력 값과 실제 출력 값을 보여주고 있으며, 그림 6.2. 는 검증데이터에 대한 기존의 GM의 성능지표 값을 보여준다. 그림 6.1.에서 x축은 콘크리트 압축 강도에 대한 검증데이터의 수를 나타내고 있으며, y축은 콘크리트 압축 강도 값을 나타낸다. 검정색 실선은 실제 콘크리트 압축 강도 값이며, 빨간색 점선은 기존 GM의 출력 값을 보여준다. 그림에서 보이는 바와 같이 GM의 출력 값이 실제 출력 값의 큰 변화는 예측하지만 작은 변화는 예측하지 못하는 것을 확인할 수 있다. 그림 6.2.에서 x축은 입력공간에서 생성되는 클러스터의 수를 나타내고 있으며, y축은 출력공간에서 생성되는 컨텍스트의 수를 나타낸다. z축은 검증데이터에 대한 성능지표 값을 보여준다. 그림에서 보이는 바와 같이 컨텍스트를 균등하게 생성할 때 컨텍스트의 수가 6, 클러스터의 수가 6일 때 성능지표 값이 0.4276으로 가장 우수한 것을 확인할 수 있다.

표 6-1. 컨텍스트를 균등하게 생성한 GM의 성능지표

P \ C	2	3	4	5	6
2	0	0	0	0	0
3	0	0	0	0	0
4	0.3165	0.3175	0.3191	0.3184	0.3191
5	0.4039	0.4184	0.4223	0.4175	0.4204
6	0.4031	0.4136	0.4183	0.4159	0.4276

표 6-2. 컨텍스트를 유연하게 생성한 GM의 성능지표

P \ C	2	3	4	5	6
2	0	0	0	0	0
3	0.0097	0.0093	0.0097	0.0093	0.0090
4	0.2931	0.2947	0.2953	0.2945	0.2948
5	0.3897	0.3962	0.3962	0.3946	0.3960
6	0.4022	0.4120	0.4183	0.4212	0.4230




그림 6.1. 기존 GM의 출력 값과 실제 출력 값 비교(컨텍스트 균등하게 생성,
 컨텍스트의 수 = 6, 클러스터의 수 = 6)




그림 6.2. 검증데이터에 대한 GM의 성능지표(컨텍스트 균등하게 생성, 컨텍스트의 수 = 6, 클러스터의 수 = 6)

표 6-3. 은 컨텍스트를 균등하게 생성한 CGK-GM의 예측 성능이며, 표 6-4. 는 컨텍스트를 유연하게 생성한 CGK-GM의 예측 성능이다. 그림 6.3. 은 CGK-GM의 출력 값과 실제 출력 값을 보여주고 있으며, 그림 6.4. 는 성능지표를 이용한 CGK-GM의 예측 성능을 보여준다. 그림 6.3. 과 같이 CGK-GM의 출력 값이 실제 출력 값의 큰 변화만을 예측하지만, 기존의 GM의 출력 값보다 실제 출력 값을 유사하게 예측하는 것을 확인할 수 있다. 그림 6.4. 는 검증데이터에 대한 CGK-GM의 성능지표 값을 보여준다. 그림에서 보이는 바와 같이 컨텍스트를 균등하게 생성할 때 컨텍스트의 수가 6, 클러스터의 수가 4일 때 성능지표 값이 0.4700으로 가장 우수한 것을 확인할 수 있다.

표 6-3. 컨텍스트를 균등하게 생성한 CGK- GM의 성능지표

P \ C	2	3	4	5	6
2	0	0	0	0	0
3	0.0204	0.0204	0.0204	0.0205	0.0206
4	0.3328	0.3315	0.3308	0.3295	0.3315
5	0.4409	0.4379	0.4350	0.4350	0.4300
6	0.4618	0.4629	0.4700	0.4618	0.4606

표 6-4. 컨텍스트를 유연하게 생성한 CGK-GM의 성능지표

P \ C	2	3	4	5	6
2	0	0	0	0	0
3	0.0295	0.0241	0.0282	0.0259	0.0233
4	0.3060	0.3070	0.3084	0.3070	0.3052
5	0.4182	0.4254	0.4183	0.4178	0.4162
6	0.4662	0.4640	0.4569	0.4466	0.4449




그림 6.3. CGK-GM의 출력 값과 실제 출력 값 비교(컨텍스트 균등하게 생성, 컨텍스트의 수 = 6, 클러스터의 수 = 4)




그림 6.4. 검증데이터에 대한 CGK-GM의 성능지표(컨텍스트 균등하게 생성, 컨텍스트의 수 = 6, 클러스터의 수 = 4)

표 6-5. 는 컨텍스트를 균등하게 생성한 AGM의 예측 성능이며, 표 6-6. 은 컨텍스트를 유연하게 생성한 AGM의 예측 성능이다. 그림 6.5. 은 AGM의 출력 값과 실제 출력 값을 보여주고 있으며, 그림 6.6. 은 성능지표를 이용한 AGM의 예측 성능을 보여준다. 그림 6.5. 와 같이 AGM의 출력 값이 비선형적 특징이 강한 실제 출력 값을 유사하게 예측하는 것을 확인할 수 있다. 그림 6.6. 은 검증데이터에 대한 CGK-GM의 성능지표 값을 보여준다. 그림에서 보이는 바와 같이 컨텍스트를 균등하게 생성할 때 컨텍스트의 수가 6, 클러스터의 수가 4일 때 성능지표 값이 0.5208으로 가장 우수한 것을 확인할 수 있다.

표 6-5. 컨텍스트를 균등하게 생성한 AGM의 성능지표

P \ C	2	3	4	5	6
2	0	0	0	0	0
3	0.0201	0.0204	0.0203	0.0202	0.0203
4	0.3194	0.3221	0.3302	0.3315	0.3295
5	0.4548	0.4587	0.4548	0.4488	0.4637
6	0.5125	0.5149	0.5208	0.5184	0.5196

표 6-6. 컨텍스트를 유연하게 생성한 AGM의 성능지표

P \ C	2	3	4	5	6
2	0	0	0	0	0
3	0.0481	0.0437	0.0446	0.0391	0.0451
4	0.3071	0.3023	0.3136	0.3187	0.3129
5	0.4344	0.4348	0.4380	0.4471	0.4418
6	0.4884	0.4981	0.4921	0.5074	0.5028




그림 6.5. AGM의 출력 값과 실제 출력 값 비교(컨텍스트 균등하게 생성, 컨텍스트의 수 = 6, 클러스터의 수 = 6)




그림 6.6. 검증데이터에 대한 AGM의 성능지표(컨텍스트 균등하게 생성, 컨텍스트의 수 = 6, 클러스터의 수 = 6)

표 6-7. 은 컨텍스트를 균등하게 생성한 optimized CGK-GM의 예측 성능이며, 표 6-8. 은 컨텍스트를 균등하게 생성한 optimized AGM의 예측 성능이다. 표 6-9. 는 optimized CGK-GM의 출력공간에 존재하는 정보 입자가 기존의 형태에서 어떻게 최적화되었는지를 보여주고 있으며, 표 6-10. 은 optimized AGM의 정보 입자가 어떻게 최적화되었는지를 보여준다. 그림 6.7. 은 optimized CGK-GM의 출력 값과 실제 출력 값을 보여주고 있으며, 그림 6.8. 은 성능지표를 이용한 optimized CGK-GM의 예측 성능을 보여준다. 그림 6.9. 는 optimized AGM의 출력 값과 실제 출력 값을 보여주고 있으며, 그림 6.10. 은 성능지표를 이용한 optimized AGM의 예측 성능을 보여준다. 그림 6.7. 은 유전 알고리즘을 이용하여 정보 입자를 최적화한 최적화된 CGK-GM의 출력 값을 보여준다. 그림에서 보이는 바와 같이 CGK-GM의 출력 값보다 최적화된 CGK-GM의 출력 값이 실제 출력 값을 보다 유사하게 예측하는 것을 확인할 수 있다. 그림 6.9. 는 최적화된 AGM의 출력 값을 보여준다. 그림 6.9. (a)와 (b)에서 보이는 바와 같이 최적화된 AGM의 출력 값이 비선형적 특징이 강한 실제 출력 값을 유사하게 예측하는 것을 확인할 수 있다.

표 6-7. 컨텍스트를 균등하게 생성한 최적화된 CGK-GM의 성능지표

P \ C	2	3	4	5	6
6	0.4497	0.4663	0.4781	0.4628	0.4687

표 6-8. 컨텍스트를 균등하게 생성한 최적화된 AGM의 성능지표

P \ C	2	3	4	5	6
6	0.5168	0.5241	0.5143	0.5252	0.5386

표 6-9. 최적화된 CGK-GM의 컨텍스트 최적화 후 업데이트된 값 확인

	p_{13}	p_{21}	p_{23}	p_{31}	p_{33}	p_{41}	p_{43}	p_{51}	p_{53}	p_{61}
기준	17.8	2.3	33.3	17.8	48.9	33.3	64.4	48.9	79.9	64.4
최적	17.7	1.6	33.2	18.2	48.2	34	64	49.9	80.6	65.1

표 6-10. 최적화된 AGM의 컨텍스트 최적화 후 업데이트된 값 확인

	p_{13}	p_{21}	p_{23}	p_{31}	p_{33}	p_{41}	p_{43}	p_{51}	p_{53}	p_{61}
기준	17.8	2.3	33.3	17.8	48.9	33.3	64.4	48.9	79.9	64.4
최적	17.4	3.3	33.2	18.5	47.9	34	64.5	49.6	78.9	65.1




그림 6.7. 최적화된 CGK-GM의 출력 값과 실제 출력 값 비교






그림 6.8. 검증데이터에 대한 최적화된 CGK-GM의 성능지표



(a) 전체 검증데이터에 대한 최적화된 AGM의 출력 값과 실제 출력 값 비교



(b) 일부 검증데이터에 대한 최적화된 AGM의 출력 값과 실제 출력 값 비교

그림 6.9. 최적화된 AGM의 출력 값과 실제 출력 값 비교




그림 6.10. 검증데이터에 대한 최적화된 AGM의 성능지표




그림 6.11. 최적화된 CGK-GM 내 유전 알고리즘의 적합도




그림 6.12. 최적화된 AGM 내 유전 알고리즘의 적합도

표 6-11. 은 콘크리트 압축 강도 예측의 실험 결과 보여준다. 표에서 보이는 바와 같이 기존의 GM은 컨텍스트를 균등하게 생성하고 컨텍스트가 6, 클러스터가 6일 때 검증데이터에 대한 성능지표 값이 0.4276인 것을 확인할 수 있다. 본 논문에서는 제안하는 방법인 CGK-GM, AGM, optimized CGK-GM, optimized AGM의 경우 컨텍스트를 균등하게 생성할 때 기존의 GM보다 우수한 예측 성능을 보이는 것을 확인할 수 있었으며 유전 알고리즘을 통해 최적화를 수행할 때 예측 성능이 개선 되는 것을 확인할 수 있다.

표 6-11. 콘크리트 압축 강도 예측의 실험 결과

입자 모델		성능지표		
		P / C	학습데이터	검증데이터
GM	Uniform	6 / 6	0.4311	0.4276
CGK-GM	Uniform	6 / 4	0.4743	0.4700
AGM	Uniform	6 / 4	0.5287	0.5208
Optimized CGK-GM	Uniform	6 / 6	0.4793	0.4781
Optimized AGM	Uniform	6 / 6	0.5367	0.5386

다음은 정수장 응집제 투여량 예측 실험의 결과를 보여준다. 표 6-12. 는 컨텍스트를 균등하게 생성한 기존 GM의 예측 성능이며, 표 6-13. 은 컨텍스트를 유연하게 생성한 기존 GM의 예측 성능이다. 그림 6.13. 은 기존 GM의 출력 값과 실제 출력 값을 보여주고 있으며, 그림 6.14. 는 검증데이터에 대한 GM의 성능지표 값을 보여준다.

표 6-12. 컨텍스트를 균등하게 생성한 GM의 성능지표

P \ C	2	3	4	5	6
	2	0	0	0	0
3	0	0	0	0	0
4	0.3314	0.3333	0.3333	0.3334	0.3334
5	0.4884	0.4942	0.4971	0.4972	0.4974
6	0.5618	0.5861	0.5861	0.5896	0.5896

표 6-13. 컨텍스트를 유연하게 생성한 GM의 성능지표

P \ C	2	3	4	5	6
2	0	0	0	0	0
3	0.1602	0.1641	0.1577	0.1540	0.1568
4	0.4098	0.4129	0.4133	0.4144	0.4099
5	0.5301	0.5466	0.5373	0.5347	0.5346
6	0.5975	0.5952	0.6111	0.6064	0.6026




그림 6.13. 기존 GM의 출력 값과 실제 출력 값 비교(컨텍스트 유연하게 생성, 컨텍스트의 수 = 6, 클러스터의 수 = 4)




그림 6.14. 검증데이터에 대한 GM의 성능지표(컨텍스트 유연하게 생성,
 컨텍스트의 수 = 6, 클러스터의 수 = 4)

표 6-14. 는 컨텍스트를 균등하게 생성한 CGK-GM의 예측 성능이며, 표 6-15.
 는 컨텍스트를 유연하게 생성한 CGK-GM의 예측 성능이다. 그림 6.15. 는 CGK-GM의
 출력 값과 실제 출력 값을 보여주고 있으며, 그림 6.16. 은 성능지표를 이용한
 CGK-GM의 예측 성능을 보여준다.

표 6-14. 컨텍스트를 균등하게 생성한 CGK-GM의 성능지표

P \ C	2	3	4	5	6
2	0	0	0	0	0
3	0	0	0	0	0
4	0.3333	0.3314	0.3314	0.3295	0.3333
5	0.4884	0.4884	0.4855	0.4942	0.4942
6	0.5584	0.5653	0.5723	0.5827	0.5827

표 6-15. 컨텍스트를 유연하게 생성한 CGK-GM의 성능지표

P \ C	2	3	4	5	6
2	0	0	0	0	0
3	0.1345	0.1038	0.1750	0.1535	0.1455
4	0.3964	0.4040	0.4100	0.4465	0.4529
5	0.5320	0.5429	0.5672	0.5382	0.5514
6	0.6029	0.6090	0.6264	0.6257	0.6059




그림 6.15. CGK-GM의 출력 값과 실제 출력 값 비교(컨텍스트 유연하게 생성, 컨텍스트의 수 = 6, 클러스터의 수 = 4)




그림 6.16. 검증데이터에 대한 CGK-GM의 성능지표(컨텍스트 유연하게 생성, 컨텍스트의 수 = 6, 클러스터의 수 = 4)

표 6-16. 은 컨텍스트를 균등하게 생성한 AGM의 예측 성능이며, 표 6-17. 은 컨텍스트를 유연하게 생성한 AGM의 예측 성능이다. 그림 6.17. 은 AGM의 출력 값과 실제 출력 값을 보여주고 있으며, 그림 6.18. 은 성능지표를 이용한 AGM의 예측 성능을 보여준다.

표 6-16. 컨텍스트를 균등하게 생성한 AGM의 성능지표

P \ C	2	3	4	5	6
2	0	0	0	0	0
3	0	0	0	0	0
4	0.3333	0.3333	0.3314	0.3333	0.3314
5	0.4884	0.4913	0.4769	0.4913	0.4855
6	0.5861	0.5723	0.5792	0.5931	0.5861

표 6-17. 컨텍스트를 유연하게 생성한 AGM의 성능지표

P \ C	2	3	4	5	6
2	0	0	0	0	0
3	0.2641	0.2710	0.2706	0.2635	0.2464
4	0.5263	0.5257	0.5043	0.5107	0.4629
5	0.6156	0.6045	0.5952	0.6053	0.5947
6	0.6471	0.6432	0.6611	0.6701	0.6535




그림 6.17. AGM의 출력 값과 실제 출력 값 비교(컨텍스트 유연하게 생성, 컨텍스트의 수 = 6, 클러스터의 수 = 5)




그림 6.18. 검증데이터에 대한 AGM의 성능지표(컨텍스트 유연하게 생성, 컨텍스트의 수 = 6, 클러스터의 수 = 5)

표 6-18. 은 컨텍스트를 균등하게 생성한 optimized CGK-GM의 예측 성능이며, 표 6-19. 는 컨텍스트를 균등하게 생성한 optimized AGM의 예측 성능이다. 표 6-20. 는 optimized CGK-GM의 출력공간에 존재하는 정보 입자가 기존의 형태에서 어떻게 최적화되었는지를 보여주고 있으며, 표 6-21. 은 optimized AGM의 정보 입자가 어떻게 최적화되었는지를 보여준다. 그림 6.19. 는 optimized CGK-GM의 출력값과 실제 출력 값을 보여주고 있으며, 그림 6.20. 은 성능지표를 이용한 optimized CGK-GM의 예측 성능을 보여준다. 그림 6.21. 은 optimized AGM의 출력값과 실제 출력 값을 보여주고 있으며, 그림 6.22. 는 성능지표를 이용한 optimized AGM의 예측 성능을 보여준다.

표 6-18. 컨텍스트를 균등하게 생성한 최적화된 CGK-GM의 성능지표

P \ C	2	3	4	5	6
6	0.6295	0.6203	0.6379	0.6086	0.6479

표 6-19. 컨텍스트를 균등하게 생성한 최적화된 AGM의 성능지표

P \ C	2	3	4	5	6
6	0.6473	0.6660	0.6543	0.6313	0.6820

표 6-20. 최적화된 CGK-GM의 컨텍스트 최적화 후 업데이트된 값 확인

	p_{13}	p_{21}	p_{23}	p_{31}	p_{33}	p_{41}	p_{43}	p_{51}	p_{53}	p_{61}
기존	16.8	13	20	16.8	23.1	20	26.7	23.1	50	26.7
최적	15.8	13.7	19	17.2	22.7	19	27.4	24.1	49.6	26

표 6-21. 최적화된 AGM의 컨텍스트 최적화 후 업데이트된 값 확인

	p_{13}	p_{21}	p_{23}	p_{31}	p_{33}	p_{41}	p_{43}	p_{51}	p_{53}	p_{61}
기존	16.8	13	19.8	16.8	22.8	19.8	26.7	22.8	50	26.7
최적	16.7	13.7	18.8	16.9	22.9	20	25.7	23.8	50.1	27.4




그림 6.19. 최적화된 CGK-GM의 출력 값과 실제 출력 값 비교




그림 6.20. 검증데이터에 대한 최적화된 CGK-GM의 성능지표




그림 6.21. 최적화된 AGM의 출력 값과 실제 출력 값 비교




그림 6.22. 검증데이터에 대한 최적화된 AGM의 성능지표




그림 6.23. 최적화된 CGK-GM 내 유전 알고리즘의 적합도




그림 6.24. 최적화된 AGM 내 유전 알고리즘의 적합도

표 6-22. 는 정수장 응집제 투여량 예측의 실험 결과 보여준다. 표와 같이 기존의 GM은 컨텍스트를 유연하게 생성하고 컨텍스트가 6, 클러스터가 4일 때 검증 데이터에 대한 성능지표 값이 0.6111인 것을 확인할 수 있다. 본 논문에서는 제안하는 방법인 CGK-GM, AGM, optimized CGK-GM, optimized AGM의 경우 컨텍스트를 균등하게 생성할 때 기존의 GM보다 우수한 예측 성능을 보이는 것을 확인할 수 있었으며 optimized AGM은 컨텍스트를 유연하게 생성하고 컨텍스트가 6, 클러스터가 6일 때 검증데이터에 대한 성능지표 값이 0.6820으로 가장 우수한 예측 성능을 보이는 것을 확인할 수 있다.

표 6-22. 정수장 응집제 투여량 예측의 실험 결과

입자 모델		성능지표		
		P / C	학습데이터	검증데이터
GM	Flexible	6 / 4	0.6100	0.6111
CGK-GM	Flexible	6 / 4	0.6217	0.6264
AGM	Flexible	6 / 5	0.6641	0.6701
Optimized CGK-GM	Flexible	6 / 6	0.6327	0.6479
Optimized AGM	Flexible	6 / 6	0.6743	0.6820

다음은 보스턴 주택 가격 예측 실험의 결과를 보여준다. 표 6-23. 은 컨텍스트를 균등하게 생성한 기존 GM의 예측 성능이며, 표 6-24. 는 컨텍스트를 유연하게 생성한 GM의 예측 성능이다. 그림 6.25. 는 기존 GM의 출력 값과 실제 출력 값을 보여주고 있으며, 그림 6.26. 은 검증데이터에 대한 기존의 GM의 성능지표 값을 보여준다.

표 6-23. 컨텍스트를 균등하게 생성한 GM의 성능지표

P \ C	2	3	4	5	6
2	0	0	0	0	0
3	0	0	0	0	0
4	0.3149	0.3162	0.3175	0.3175	0.3162
5	0.4644	0.4644	0.4664	0.4644	0.4664
6	0.5383	0.5383	0.5431	0.5431	0.5360

표 6-24. 컨텍스트를 유연하게 생성한 GM의 성능지표

P \ C	2	3	4	5	6
2	0	0	0	0	0
3	0.0119	0.0132	0.0152	0.0163	0.0160
4	0.2885	0.2906	0.3011	0.2969	0.2960
5	0.4388	0.4389	0.4447	0.4456	0.4434
6	0.5180	0.5222	0.5340	0.5333	0.5292




그림 6.25. 기존 GM의 출력 값과 실제 출력 값 비교(컨텍스트 균등하게 생성, 컨텍스트의 수 = 6, 클러스터의 수 = 4)

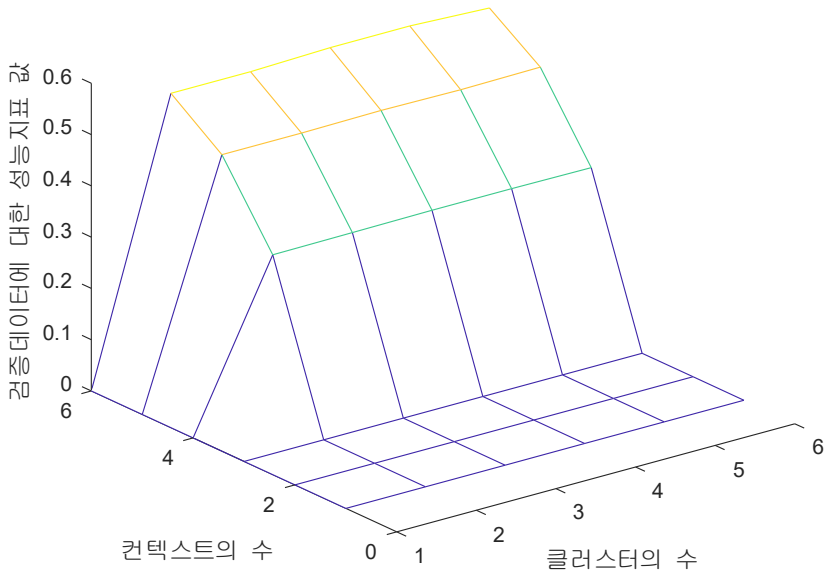


그림 6.26. 검증데이터에 대한 GM의 성능지표(컨텍스트 균등하게 생성,
 컨텍스트의 수 = 6, 클러스터의 수 = 4)

표 6-25. 는 컨텍스트를 균등하게 생성한 CGK-GM의 예측 성능이며, 표 6-26. 은 컨텍스트를 유연하게 생성한 CGK-GM의 예측 성능이다. 그림 6.27. 은 CGK-GM의 출력 값과 실제 출력 값을 보여주고 있으며, 그림 6.28. 은 성능지표를 이용한 CGK-GM의 예측 성능을 보여준다.

표 6-25. 컨텍스트를 균등하게 생성한 CGK-GM의 성능지표

P \ C	2	3	4	5	6
2	0	0	0	0	0
3	0	0	0	0	0
4	0.3175	0.3175	0.3162	0.3202	0.3188
5	0.4684	0.4644	0.4625	0.4723	0.4664
6	0.5431	0.5431	0.5478	0.5502	0.5502

표 6-26. 컨텍스트를 유연하게 생성한 CGK-GM의 성능지표

P \ C	2	3	4	5	6
2	0	0	0	0	0
3	0.0270	0.0252	0.0232	0.0239	0.0216
4	0.2705	0.3028	0.2862	0.3061	0.2984
5	0.4351	0.4476	0.4450	0.4452	0.4470
6	0.5220	0.5150	0.5397	0.5302	0.5115




그림 6.27. CGK-GM의 출력 값과 실제 출력 값 비교(컨텍스트 균등하게 생성, 컨텍스트의 수 = 6, 클러스터의 수 = 5)

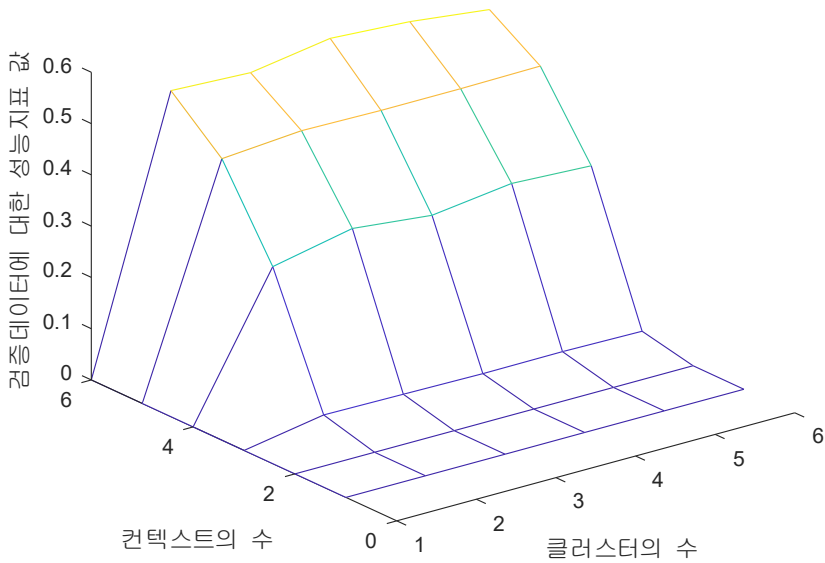


그림 6.28. 검증데이터에 대한 CGK-GM의 성능지표(컨텍스트 균등하게 생성, 컨텍스트의 수 = 6, 클러스터의 수 = 5)

표 6-27. 은 컨텍스트를 균등하게 생성한 AGM의 예측 성능이며, 표 6-28. 은 컨텍스트를 유연하게 생성한 AGM의 예측 성능이다. 그림 6.29. 는 AGM의 출력 값과 실제 출력 값을 보여주고 있으며, 그림 6.30. 은 성능지표를 이용한 AGM의 예측 성능을 보여준다.

표 6-27. 컨텍스트를 균등하게 생성한 AGM의 성능지표

P \ C	2	3	4	5	6
2	0	0	0	0	0
3	0.0133	0.0132	0.0133	0.0133	0.0132
4	0.3368	0.3341	0.3355	0.3355	0.3368
5	0.4846	0.4906	0.4826	0.4886	0.4766
6	0.5599	0.5718	0.5694	0.5455	0.5671

표 6-28. 컨텍스트를 유연하게 생성한 AGM의 성능지표

P \ C	2	3	4	5	6
2	0	0	0	0	0
3	0.0767	0.0720	0.0663	0.0677	0.0670
4	0.3346	0.3437	0.3377	0.3361	0.3236
5	0.4993	0.4853	0.4855	0.4920	0.4852
6	0.5669	0.5870	0.5807	0.5690	0.5614




그림 6.29. AGM의 출력 값과 실제 출력 값 비교(컨텍스트 유연하게 생성, 컨텍스트의 수 = 6, 클러스터의 수 = 3)




그림 6.30. 검증데이터에 대한 AGM의 성능지표(컨텍스트 유연하게 생성, 컨텍스트의 수 = 6, 클러스터의 수 = 3)

표 6-29. 는 컨텍스트를 균등하게 생성한 optimized CGK-GM의 예측 성능이며, 표 6-30. 은 컨텍스트를 균등하게 생성한 optimized AGM의 예측 성능이다. 표 6-31. 은 optimized CGK-GM의 출력공간에 존재하는 정보 입자가 기존의 형태에서 어떻게 최적화되었는지를 보여주고 있으며, 표 6-32. 는 optimized AGM의 정보 입자가 어떻게 최적화되었는지를 보여준다. 그림 6.31. 은 optimized CGK-GM의 출력 값과 실제 출력 값을 보여주고 있으며, 그림 6.32. 는 성능지표를 이용한 optimized CGK-GM의 예측 성능을 보여준다. 그림 6.33. 은 optimized AGM의 출력 값과 실제 출력 값을 보여주고 있으며, 그림 6.34. 는 성능지표를 이용한 optimized AGM의 예측 성능을 보여준다.

표 6-29. 컨텍스트를 균등하게 생성한 최적화된 CGK-GM의 성능지표

P \ C	2	3	4	5	6
6	0.5452	0.5707	0.5632	0.5733	0.5730

표 6-30. 컨텍스트를 균등하게 생성한 최적화된 AGM의 성능지표

P \ C	2	3	4	5	6
6	0.5918	0.5983	0.5973	0.5894	0.6069

표 6-31. 최적화된 CGK-GM의 컨텍스트 최적화 후 업데이트된 값 확인

	p_{13}	p_{21}	p_{23}	p_{31}	p_{33}	p_{41}	p_{43}	p_{51}	p_{53}	p_{61}
기존	14	5	23	14	32	23	41	32	50	41
최적	13.3	6	22.3	14.7	31	24	40	33	49	41.4

표 6-32. 최적화된 AGM의 컨텍스트 최적화 후 업데이트된 값 확인

	p_{13}	p_{21}	p_{23}	p_{31}	p_{33}	p_{41}	p_{43}	p_{51}	p_{53}	p_{61}
기존	15.6	5.6	20.8	15.6	25.2	20.8	30.4	25.2	50	30.4
최적	14.6	6.3	19.8	16.6	24.2	20.9	29.4	25.9	49	31.1




그림 6.31. 최적화된 CGK-GM의 출력 값과 실제 출력 값 비교






그림 6.32. 검증데이터에 대한 최적화된 CGK-GM의 성능지표



(a) 전체 검증데이터에 대한 최적화된 AGM의 출력 값과 실제 출력 값 비교



(b) 일부 검증데이터에 대한 최적화된 AGM의 출력 값과 실제 출력 값 비교

그림 6.33. 최적화된 AGM의 출력 값과 실제 출력 값 비교




그림 6.34. 검증데이터에 대한 최적화된 AGM의 성능지표




그림 6.35. 최적화된 CGK-GM 내 유전 알고리즘의 적합도




그림 6.36. 최적화된 AGM 내 유전 알고리즘의 적합도

표 6-33. 은 보스턴 주택 가격 예측의 실험 결과 보여준다. 표와 같이 GM은 컨텍스트를 균등하게 생성하고 컨텍스트가 6, 클러스터가 4일 때 검증데이터에 대한 성능지표 값이 0.5431인 것을 확인할 수 있다. 본 논문에서는 제안하는 방법인 CGK-GM, AGM, optimized CGK-GM, optimized AGM의 경우 컨텍스트를 균등하게 생성할 때 기존의 GM보다 우수한 예측 성능을 보이는 것을 확인할 수 있었으며 optimized AGM은 컨텍스트를 유연하게 생성하고 컨텍스트가 6, 클러스터가 6일 때 검증데이터에 대한 성능지표 값이 0.6069로 가장 우수한 예측 성능을 보이는 것을 확인할 수 있다.

표 6-33. 보스턴 주택 가격 예측의 실험 결과

입자 모델		성능지표		
		P / C	학습데이터	검증데이터
GM	Uniform	6 / 4	0.5410	0.5431
CGK-GM	Uniform	6 / 5	0.5476	0.5502
AGM	Flexible	6 / 3	0.5842	0.5870
Optimized CGK-GM	Uniform	6 / 5	0.5698	0.5733
Optimized AGM	Flexible	6 / 6	0.6100	0.6069

예측 관련 벤치마킹 데이터베이스 3개를 이용하여 실험을 진행한 결과, 기존의 GM보다 본 논문에서 제안하는 방법인 CGK-GM, AGM이 우수한 예측 성능을 보이는 것을 확인할 수 있었으며 유전 알고리즘을 통해 정보 입자 최적화할 경우 예측 성능이 개선됨을 확인할 수 있다. 출력공간에서 컨텍스트를 생성하는 방법과 컨텍스트 및 클러스터의 수를 설정할 때 데이터베이스에 따라 차이를 확인할 수 있다.

7장 결론

본 논문은 계층적인 구조와 최적의 정보 입자 할당에 근거한 퍼지 기반 입자 모델의 설계 및 최적화 방법을 제안했다. 기존의 퍼지 클러스터링은 유클리디안 거리를 이용하여 클러스터의 중심과 각각의 데이터 사이의 거리를 계산하여 클러스터를 생성한다. 하지만, 데이터가 기하학적인 특징을 가질 때 성능이 감소하는 문제가 있다. 이러한 문제점을 개선하기 위해 GK 클러스터링이 사용된다. GK 클러스터링은 마할라노비스 거리를 이용하여 클러스터의 중심과 각각의 데이터 사이의 거리를 계산하여 기하학적 형태의 클러스터를 생성한다. 본 논문은 기존의 GK 클러스터링에서 출력공간을 고려하는 방법을 추가한 컨텍스트 기반 GK(CGK) 클러스터링을 제안하여 입력공간뿐만 아니라 출력공간까지 고려한 클러스터를 생성하기 때문에 기존의 GK 클러스터링보다 효과적으로 클러스터를 생성할 수 있다. 제안한 CGK 클러스터링을 이용하여 CGK 기반 입자 모델(CGK-GM), 집계형 구조의 CGK 기반 입자 모델(AGM), 최적화된 CGK 기반 입자 모델(optimized CGK-GM), 최적화된 집계형 구조의 CGK 기반 입자 모델(optimized AGM)을 설계했다. 제안한 CGK 기반 입자 모델의 장점은 다음과 같이 정리할 수 있다.

- 기존의 신경회로망과 다르게 수치적인 입출력 데이터로부터 입력공간 및 출력공간에서 정보 입자를 생성하여 언어적으로 표현할 수 있는 설명 가능한 의미 있는 퍼지 IF-THEN 형태의 규칙을 자동으로 생성할 수 있다.
- 기존의 퍼지 클러스터링과 다르게 기하학적 형태의 클러스터를 생성할 수 있어서 기하학적 특징을 가진 수치적인 입출력 데이터베이스를 처리하는 데 효과적이다.
- CGK 기반 입자 모델의 출력이 컨텍스트 형태이기 때문에 예측 결과를 언어적으로 표현할 수 있어 설명 가능한 결과를 표현할 수 있다.
- 일반적인 예측 모델인 선형회귀 모델, 신경회로망, 그리고 방사기저함수 신경망과 본 논문에서 제안하는 CGK 기반 입자 모델을 하위 모델과 상위 모델로 결합

하는 집계형 구조의 CGK 기반 입자 모델을 설계하였다. 이를 통해 수치적인 입 출력 데이터에서 유형1 정보 입자와 유형2 정보 입자를 생성했다. 유형 단계가 발전됨에 따라 높은 추상화 값을 갖는 의미 있는 정보 입자를 생성할 수 있다.

- 최종 출력이 수치적인 값으로 나타내는 일반적인 예측 모델과 달리 입자 모델은 최종 출력이 정보 입자로 나타나기 때문에 정보 입자의 범위성과 특이성을 고려한 입자 모델에 맞는 성능 평가 방법인 성능지표를 이용하여 기존의 입자 모델과 제안하는 입자 모델들의 성능을 비교 분석했다.
- 최적화 알고리즘을 이용하여 입력공간 및 출력공간에 생성된 정보 입자를 최적 할당할 수 있으며 이를 이용하여 CGK 기반 입자 모델의 예측 성능을 개선할 수 있다.

제안하는 방법인 CGK 기반 입자 모델, 집계형 구조의 CGK 기반 입자 모델, 최적화된 CGK 기반 입자 모델, 최적화된 집계형 구조의 CGK 기반 입자 모델의 타당성을 검증하기 위해 3가지의 예측 관련 벤치마킹 데이터베이스를 이용하여 실험을 진행했다. 각각의 입자 모델의 성능을 평가하기 위해 합리적인 정보 입자를 생성할 때 고려하는 정보 입자의 범위성과 특이성을 이용한 성능지표를 사용했다. 실험 결과, 기존의 입자 모델보다 제안하는 방법들이 우수한 것을 확인할 수 있었으며, 최적화 알고리즘인 유전 알고리즘을 이용하여 정보 입자를 최적화한 최적화된 집계형 구조의 CGK 기반 입자 모델이 가장 우수한 예측 성능을 보이는 것을 확인했다. 출력공간에서 컨텍스트를 생성할 때는 데이터베이스의 특징을 고려하여 균등하게 생성하는 방법 또는 유연하게 생성하는 방법을 선택해야 한다. 컨텍스트와 클러스터의 수도 실험을 통해 최적의 값을 선택해야 한다.

향후 합리적인 정보 입자 생성 원리를 기반으로 다양한 형태의 정보 입자를 생성하는 연구 및 입력공간 및 출력공간에 생성된 정보 입자를 최적 할당하는 연구를 수행할 계획이다. 또한, 집계형 구조뿐만 아니라 다른 형태의 계층적 구조와 예측 모델을 결합한 정보 입자를 설계할 계획이다.

참고문헌

- [1] R. L. U. Cazarez, N. G. Diaz, L. S. Equigua, “Multi-layer adaptive fuzzy inference system for predicting student performance in online higher education”, IEEE Latin America Transactions, Vol. 19, No. 1, pp. 98–106 2021.
- [2] C. U. Yeom, K. C. Kwak, “Performance comparison of ANFIS models by input space partitioning methods”, Symmetry, Vol. 10, No. 12, 2018.
- [3] K. E. H. K. Ishak, M. A. Ayoub, “Predicting the efficiency of the oil removal from surfactant and polymer produced water by using liquid-liquid hydrocyclone comparison of prediction abilities between response surface methodology”, IEEE Access, Vol. 7, pp. 179605–179619, 2019.
- [4] K. Elbaz, S. L. Shen, W. J. Sun, Z. Y. Yin, A. Zhou, “Prediction model of shield performance during tunneling via incorporating improved particle swarm optimization into ANFIS”, IEEE Access, Vol. 8, pp. 39659–39671, 2020.
- [5] J. A. M. Saucedo, J. D. Hemanth, U. Kose, “Prediction of electroencephalogram time series with electro-search optimization algorithm trained adaptive neuro-fuzzy inference system”, IEEE Access, Vol. 7, pp. 15832–15844, 2019.
- [6] M. Alreshoodi, E. Danish, J. Woods, A. Fernando, C. D. Alwis, “Prediction of perceptual quality for mobile video using fuzzy inference systems”, IEEE Transactions on Consumer Electronics, Vol. 61, No. 4, pp. 546–554, 2015.
- [7] S. Sahoo, S. K. Panda, D. K. Pratihari, S. Mukhopadhyay, “Prediction of step length using neuro-fuzzy approach suitable for prosthesis control”, IEEE Transactions on Instrumentation and Measurement, Vol. 69, No. 8, pp. 5658–5665, 2020.
- [8] H. Q. Cao, H. X. Nguyen, T. T. Nguyen, V. Q. Nguyen, J. W. Jeon,

- “Robot calibration method based on extended kalman filter–dual quantum behaved particle swarm optimization and adaptive neuro–fuzzy inference system”, IEEE Access, Vol. 9, pp. 132558–132568, 2021.
- [9] C. Ai, L. Jia, M. Hong, C. Zhang, “Short-term road speed forecasting based on hybrid RBF neural network with the aid of fuzzy system–based techniques in urban traffic flow”, IEEE Access, Vol. 8, pp. 69461–69470, 2020.
- [10] J. An, L. Fu, W. Chen, J. Zhen, “A novel fuzzy–based convolutional neural network method to traffic flow prediction with uncertain traffic accident information”, IEEE Access, Vol. 7, pp. 20708–20722, 2019.
- [11] C. U. Yeom, K. C. Kwak, “Adaptive neuro–fuzzy inference system predictor with an incremental tree structure based on a context–based fuzzy clustering approach”, Applied Sciences, Vol. 10, No. 23, 2020.
- [12] M. Parsapoor, U. Bilstrupo, B. Svensson, “Forecasting solar activity with computational intelligence models”, IEEE Access, Vol. 6, pp. 70902–70909, 2018.
- [13] K. Kannadasan, D. R. Edla, M. H. Yadav, A. Bablani, “Intelligent–ANFIS model for predicting measurement of surface roughness and geometric tolerances in three–axis CNC milling”, IEEE Transactions on Instrumentation and Measurement, Vol. 69, No. 10, pp. 7683–7694, 2020.
- [14] H. Guo, W. Zeng, Y. Shi, J. Deng, L. Zhao, “Kernel granger causality based on back propagation neural network fuzzy inference system on fMRI data”, IEEE Transactions on Neural Systems and Rehabilitation Engineering, Vol. 28, No. 5, pp. 1049–1058, 2020.
- [15] Y. Hwang, B. Kang, W. Kim, “Motion cue–based sudden pedestrian behavior prediction using fuzzy inference”, IEEE Access, Vol. 9, pp. 135245–135255, 2021.
- [16] Y. Ding, S. Yang, Y. Chen, Q. Long, J. Wei, “Explaining and

- predicting mobile government microblogging services participation behaviors a SEM-neural network method” , IEEE Access, Vol. 7, pp. 39600–39611, 2019.
- [17] B. Ibragimov, D. A. S. Toesca, Y. Yuan, A. C. Koong, D. T. Chang, L. Xing, “Neural networks for deep radiotherapy dose analysis and prediction of liver SBRT outcomes” , IEEE Journal of Biomedical and Health Informatics, Vol. 23, No. 5, pp. 1821–1833, 2019.
- [18] T. Jia, P. Yan, “Predicting citywide road traffic flow using deep spatiotemporal neural networks” , IEEE Transactions on Intelligent Transportation Systems, Vol. 22, No. 5, pp. 3101–3111, 2020.
- [19] Q. Wu, Z. Jiang, K. Hong, H. Liu, L. T. Yang, J. Ding, “Tensor-based recurrent neural network and multi-modal prediction with its applications in traffic network management” , IEEE Transactions on Network and Service Management, Vol. 18, No. 1, pp. 780–792, 2021.
- [20] M. Bouda, G. Krishna, J. Krystofik, S. Oda, P. Palacharla, “Towards vendor-agnostic real-time optical network design with extended Kalman state estimation and recurrent neural network machine learning Invited” , Journal of Optical Communications and Networking, Vol. 13, No. 4, pp. B21–B34, 2021.
- [21] Y. T. Liu, Y. Y. Lin, S. L. Wu, C. H. Chuang, C. T. Lin, “Brain dynamics in predicting driving fatigue using a recurrent self-evolving fuzzy neural network” , IEEE Transactions on Neural Networks and Learning Systems, Vol. 27, No. 2, pp. 347–360, 2015.
- [22] T. Dumas, A. Roumy, C. Guillemot, “Context-adaptive neural network-based prediction for image compression” , IEEE Transactions on Image Processing, Vol. 29, pp. 679–693, 2019.
- [23] J. W. Lin, C. T. Chao, J. S. Chiou, “Determining neuronal number in each hidden layer using earthquake catalogues as training data in training an embedded back propagation neural network for predicting earthquake magnitude” , IEEE Access, Vol. 6, pp. 52582–52597, 2018.

- [24] J. Yang, L. Li, Y. Shi, X. Xie, “An ARIMA model with adaptive orders for predicting blood glucose concentrations and hypoglycemia” , IEEE Journal of Biomedical and Health Informatics, Vol. 23, No. 3, pp. 1251-1260, 2018.
- [25] Y. Weng, X. Wang, J. Hua, H. Wang, M. Kang, F. Y. Wang, “Forecasting horticultural products price using ARIMA model and neural network based on a large-scale data set collected by web crawler” , IEEE Transactions on Computational Social Systems, Vol. 6, No. 3, pp. 547-553, 2019.
- [26] M. U. Yousuf, I. A. Bahadly, E. Avci, “Short-term wind speed forecasting based on hybrid MODWT-ARIMA-markov model” , IEEE Access, Vol. 9, pp. 79695-79711, 2021.
- [27] C. Ding, J. Duan, Y. Zhang, X. Wu, G. Yu, “Using an ARIMA-GARCH modeling approach to improve subway short-term ridership forecasting accounting for dynamic volatility” , IEEE Transaction on Intelligent Transportation Systems, Vol. 19, No. 4, pp. 1054-1064, 2017.
- [28] J. Pati, B. Kumar, D. Manjhi, K. K. Shukla, “A comparison among ARIMA, BP-NN, and MOGA-NN for software clone evolution prediction” , IEEE Access, Vol. 5, pp. 11841-11851, 2017.
- [29] S. M. T. Nezhad, M. Nazari, E. A. Gharavol, “A novel DoS and DDoS attacks detection algorithm using ARIMA time series model and chaotic system in computer networks” , IEEE Communications Letters, Vol. 20, No. 4, pp. 700-703, 2016.
- [30] C. Yan, Y. Zhang, W. Zhong, C. Zhang, B. Xin, “A truncated SVD-based ARIMA model for multiple QoS prediction in mobile edge computing” , Tsinghua Science and Technology, Vol. 27, No. 2, pp. 315-324, 2021.
- [31] W. Pedrycz, A. V. Vasilakos, “Linguistic models and linguistic modeling” , IEEE Transactions on Systems, Man, and Cybernetics, Part B, Vol. 29, No. 6, pp. 745-757, 1999.
- [32] A. Bargiela, W. Pedrycz, Granular Computing an introduction, Kluwer

- Academic Publishers, 2003.
- [33] X. Zhu, W. Pedrycz, Z. Li, “Granular models and granular outliers” , IEEE Transactions on Fuzzy Systems, Vol. 26, No. 6, pp. 3835–3846, 2018.
- [34] R. A. Hmouz, W. Pedrycz, A. S. Balamash, A. Morfeq, “Hierarchical system modeling” , IEEE Transactions on Fuzzy Systems, Vol. 26, No. 1, pp. 258–269, 2017.
- [35] W. Pedrycz, W. Homenda, A. Jastrzebska, F. Yu, “Information granules and granular models selected design investigations” , 2020 IEEE International Conference on Fuzzy Systems, 2020.
- [36] Y. Liu, J. Zhao, W. Wang, W. Pedrycz, “Prediction intervals for granular data streams based on evolving type-2 fuzzy granular neural network dynamic ensemble” , IEEE Transactions on Fuzzy Systems, Vol. 29, No. 4, pp. 874–888, 2020.
- [37] S. Wang, W. Pedrycz, “Robust granular optimization a structured approach for optimization under integrated uncertainty” , IEEE Transactions on Fuzzy Systems, Vol. 23, No. 5, pp. 1372–1386, 2014.
- [38] X. Zhu, W. Pedrycz, Z. Li, “A development of granular input space in system modeling” , IEEE Transactions on Cybernetics, Vol. 51, 3, pp. 1639–1650, 2019.
- [39] H. Q. Truong, L. T. Ngo, W. Pedrycz, “Advanced fuzzy possibilistic C-means clustering based on granular computing” , 2016 IEEE International Conference on Systems, Man, and Cybernetics, 2016.
- [40] H. Zuo, G. Zhang, W. Pedrycz, V. Behbood, J. Lu, “Granular fuzzy regression domain adaptation in Takagi-Sugeno fuzzy models” , IEEE Transactions on Fuzzy Systems, Vol. 26, No. 2, pp. 847–858, 2017.
- [41] X. Hu, W. Pedrycz, X. Wang, “Granular fuzzy rule-based models a study in a comprehensive evaluation and construction of fuzzy models” , IEEE Transactions on Fuzzy Systems, Vol. 25, No. 5, pp. 1342–1355, 2016.
- [42] J. Zhao, Z. Han, W. Pedrycz, W. Wang, “Granular model of long-term

- prediction for energy system in steel industry” , IEEE Transactions on Cybernetics, Vol. 46, No. 2, pp. 388-400, 2015.
- [43] S. E. E. Khamy, R. A. Sadek, M. A. E. Khoreby, “An efficient brain mass detection with adaptive clustered based fuzzy C-mean and thresholding” , 2015 IEEE International Conference on Signal and Image Processing Applications, 2016.
- [44] A. B. dor, R. Shamir, Z. Yakhini, “Clustering gene expression patterns” , Journal of Computational Biology, Vol. 6, No. 3-4, 2004.
- [45] A. Kashanipour, A. R. Kashanipour, N. S. Milani, P. Akhlaghi, K. K. Boukani, “Robust color classification using fuzzy reasoning and genetic algorithms in roboCup soccer leagues” , Robot Soccer World Cup11, pp. 548-555, 2008.
- [46] J. C. Bezdek, Pattern recognition with fuzzy objective function algorithms, ISBN 0-306-40671-31, 1981.
- [47] L. Silva, R. Moura, A. M. P. Canuto, R. H. N. Santiago, B. Bedregal, “An interval-based framework for fuzzy clustering applications” , IEEE Transactions on Fuzzy Systems, Vol. 23, No. 6, pp. 2174-2187, 2015.
- [48] W. Pedrycz, “Conditinal fuzzy C-means” , Pattern Recognition Letter, Vol. 17, No. 6, pp. 625-632, 1996.
- [49] W. Pedrycz, “Conditional fuzzy clustering in the design of radial basis function neural networks” , IEEE Transactions on Neural Networks, Vol. 9, No. 4, pp. 601-612, 1998.
- [50] D. E. Gustafuson, W. C. Kessel, “Fuzzy clustering with a fuzzy covariance matrix” , 1978 IEEE Conference on Decision and Control including the 17th Symposium on Adaptive Precesses, 1979.
- [51] R. Babuska, “Fuzzy modeling for control” , Kluwer Academic Publishers, 1998.
- [52] R. Babuska, P. J. van der Veen, U. Kaymak, "Improved covariance estimation for Gustafuson-Kessel clustering", Proceedings of the 2002 IEEE International Conference on Fuzzy Systems, pp. 1081-1085, 2002.

- [53] L. A. Zadeh, "Toward a theory of fuzzy information granulation and its centrality in human reasoning and fuzzy logic", *Fuzzy Sets Systems*, Vol. 90, No. 2, pp. 111-127, 1997.
- [54] L. A. Zadeh, "From computing with numbers to computing with words. From manipulation of measurements to manipulation of perceptions", *IEEE Transactions on Circuits and Systems I: Fundamental Theory and Applications*, Vol. 46, No. 1, pp. 105-119, 1999.
- [55] T. T. Nguyen, X. C. Pham, A. W. C. Liew, W. Pedrycz, "Aggregation of classifiers a justifiable information granularity approach", *IEEE Transactions on Cybernetics*, Vol. 49, No. 6, pp. 2168-2177, 2018.
- [56] B. Zhang, W. Pedrycz, X. Wang, A. Gacek, "Design of interval type-2 information granules based on the principle of justifiable granularity", *IEEE Transactions on Fuzzy Systems*, Vol. 29, No. 11, pp. 3456-3469, 2020.
- [57] D. Wang, W. Pedrycz, Z. Li, "Granular data aggregation an adaptive principle of the justifiable granularity approach", *IEEE Transactions on Cybernetics*, Vol. 49, No. 2, pp. 417-426, 2018.
- [58] D. Wang, W. Pedrycz, Z. Li, "A two-phase development of fuzzy rule-based model and their analysis", *IEEE Access*, Vol. 7, pp. 80328-80341, 2019.
- [59] W. Pedrycz, X. Wang, "Designing fuzzy sets with the use of the parametric principle of justifiable granularity", *IEEE Transactions on Fuzzy Systems*, Vol. 24, No. 2, pp. 489-496, 2015.
- [60] B. Zhang, W. Pedrycz, A. R. Fayek, A. Gacek, Y. Dong, "Granular aggregation of fuzzy rule-based models in distributed data environment", *IEEE Transactions on Fuzzy Systems*, Vol. 29, No. 5, pp. 1297-1310, 2020.
- [61] D. Wang, W. Pedrycz, Z. Li, "Granular data aggregation an adaptive principle of the justifiable granularity approach", *IEEE Transactions on Cybernetics*, Vol. 49, No. 2, pp. 417-426, 2018.

- [62] W. Lu, D. Wang, W. Pedrycz, L. Zhang, J. Yang, X. Liu, “Granular fuzzy modeling for multidimensional numeric data A layered approach based on hyperbox” , IEEE Transactions on Fuzzy Systems, Vol. 27, No. 4, pp. 775–789, 2018.
- [63] B. Zhang, Y. Dong, X. Feng, W. Pedrycz, “Maximum fuzzy consensus feedback mechanism with minimum cost and private interest in group decision-making” , IEEE Transactions on Fuzzy Systems, Vol. 29, No. 9, pp. 2689–2700, 2020.
- [64] L. Wang, Z. Han, W. Pedrycz, J. Zhao, “A granular computing-based hybrid hierarchical method for construction of long-term prediction intervals for gaseous system of steel industry” , IEEE Access, Vol. 8, pp. 63538–63550, 2020.
- [65] W. Pedrycz, R. A. Hmouz, A. S. Balamash, A. Morfeq, “Hierarchical granular clustering an emergence of information granules of higher type and higher order” , IEEE Transactions on Fuzzy Systems, Vol. 23, No. 6, pp. 2270–2283, 2015.
- [66] Siddique, Nazmul, H. Adeli, Computational intelligence: Synergies of fuzzy logic, neural networks and evolutionary computing, Oxford, UK: John Wiley&Sons Ltd, 2013.
- [67] D. A. Freedman, Statistical models: Theory and Practice, Cambridge University, 2009.
- [68] H. T. Siegelmann, E. D. Sontag, “Turing computability with neural nets” , Appl. Math. Lett., pp. 1–15, 1991.
- [69] D. S. Broomhead, D. Lowe, “Multivariable functional interpolation and adaptive networks” , Complex Systems, Vol. 2, pp. 321–355, 1988.
- [70] X. Zhu, W. Pedrycz, Z. Li, “A design of granular Takagi–Sugeno fuzzy model through the synergy of fuzzy subspace clustering and optimal allocation of information granularity” , IEEE Transactions on Fuzzy Systems, Vol. 26, No. 5, pp. 2499–2509, 2018.
- [71] X. Zhu, W. Pedrycz, Z. Li, “A development of granular input space

- in system modeling” , IEEE Transactions on Cyberneics, Vol. 51, No. 3, pp. 1639–1650, 2019.
- [72] W. Lu, W. Pedrycz, J. Yang, X. Liu, “Granular fuzzy modeling guided through the synergy of granulating output space and clustering input subspaces” , IEEE Transactions on Cybernetics, Vol. 51, No. 5, pp. 2625–2638, 2019.
- [73] UCI Machine Learning Repository, Concrete compressive strength data set, <https://archive.ics.uci.edu/ml/datasets/Concrete+Compressive+Strength>
- [74] <http://lib.stat.cmu.edu/datasets/boston>
- [75] K. C. Kwak et al. “Application of ANFIS for coagulant dosing process in a water purification plant” , IEEE International Fuzzy Systems Conference Proceedings, 1999.