

면역알고리즘 기반의 MECs (에너지 허브) 시스템

An Immune Algorithm based Multiple Energy Carriers System

손병락*† · 강유경** · 이현***

Son Byungrak*† , Kang Yu-Kyung** and Lee Hyun***

(Submit date : 2014. 7. 2., Judgment date : 2014. 7. 2., Publication decide date : 2014. 8. 11.)

Abstract : Recently, in power system studies, Multiple Energy Carriers (MECs) such as Energy Hub has been broadly utilized in power system planners and operators. Particularly, Energy Hub performs one of the most important role as the intermediate in implementing the MECs. However, it still needs to be put under examination in both modeling and operating concerns. For instance, a probabilistic optimization model is treated by a robust global optimization technique such as multi-agent genetic algorithm (MAGA) which can support the online economic dispatch of MECs. MAGA also reduces the inevitable uncertainty caused by the integration of selected input energy carriers. However, MAGA only considers current state of the integration of selected input energy carriers in conjunctive with the condition of smart grid environments for decision making in Energy Hub. Thus, in this paper, we propose an immune algorithm based Multiple Energy Carriers System which can adopt the learning process in order to make a self decision making in Energy Hub. In particular, the proposed immune algorithm considers the previous state, the current state, and the future state of the selected input energy carriers in order to predict the next decision making of Energy Hub based on the probabilistic optimization model. The below figure shows the proposed immune algorithm based Multiple Energy Carriers System. Finally, we will compare the online economic dispatch of MECs of two algorithms such as MAGA and immune algorithm based MECs by using Real Time Digital Simulator (RTDS).

Key Words : Multiple Energy Carriers, Immune Algorithm, Decision Making, Multi-agent Genetic Algorithm (MAGA), Real Time Digital Simulator (RTDS)

*† 손병락(교신저자): 대구경북과학기술원 웰니스융합연구센터 *† Son Byungrak(corresponding author) : Wellness Convergence Research Center, DGIST.
E-mail : brson@dgist.ac.kr, Tel : 053-785-4772

**강유경 : 선문대학교 컴퓨터공학과

E-mail : brson@dgist.ac.kr, Tel : 053-785-4772

***이현 : 선문대학교 컴퓨터공학과

**Kang Yu-Kyung : Dept. of Computer Science and Engineering, Sun Moon University.

***Lee Hyun : Dept. of Computer Science and Engineering, Sun Moon University

1. 서 론

스마트 그리드(Smart Grid)는 발전-송전-배전-판매의 단계로 이루어지던 기존의 단방향 전력망에 IT기술을 접목하여 전력 공급자와 소비자가 양방향으로 실시간 정보를 교환함으로써 에너지 효율을 최적화하는 차세대 지능형 전력망을 의미한다. 발전소와 송·배전 시설과 전력 소비자를 정보통신망으로 연결하여 양방향으로 공유하는 정보를 통해 전력시스템 전체가 하나의 유기체처럼 효율적으로 작동하는 것이 스마트 그리드의 기본 개념이다(Fig. 1참조)[1-3]. 스마트 그리드가 구축되면 양방향·실시간 전력정보 교환을 통하여 합리적 에너지 소비를 유도할 수 있고, 고품질의 에너지 및 다양한 부가서비스 등을 제공할 수 있다. 또한, 신재생에너지, 전기자동차 등 청정녹색기술의 접목과 확장이 용이한 개방형 시스템으로 산업간 융합을 통해 새로운 비즈니스와 고용 창출이 가능하다.



Fig. 1 Concept of Smart Grid

에너지 허브는 풍력, 태양광, 연료전지, 바이오매스 등 다양한 신재생에너지를 입력으로

받아서 전기 또는 열에너지와 같이 필요한 에너지로 변환하여 출력하거나 저장하는 기능을 제공한다(Fig.2참조). 일반적으로 에너지 허브는 에너지 생산자, 소비자, 운송 기반시설들 사이에 인터페이스로서, 입력된 다양한 종류의 에너지를 최적화하여 출력하는 것이 목적이다. 최근, 이와 같은 에너지 허브의 최적화를 위한 다양한 알고리즘들이 제안되고 있다[4-6]. 예로, 기존 연구[5]에서는 유전자 알고리즘을 확장한 Multi-Agent Genetic Algorithm (MAGA)을 사용하여 에너지 허브의 최적화를 위한 방법을 제안하였다. 그러나, MAGA는 단순히 현재 입력된 에너지들의 상태만을 고려하여 출력 에너지를 결정하는 방식으로, 다양한 환경변화에 대한 정보를 반영하지 못하고, 이전 상태와 현재 상태를 토대로 다음 상태를 예측하지 못하는 단점을 갖고 있다. 따라서 본 논문에서는 인공면역 (Artificial Immune) 알고리즘을 적용하여 변화되는 다양한 환경정보를 반영하고, 이전 (Previous) 상태와 현재 (Current) 상태를 고려한 다음 (Future) 상태를 예측하여 스스로 출력 에너지를 결정할 수 있는 최적화된 에너지 허브를 제안하고자 한다.

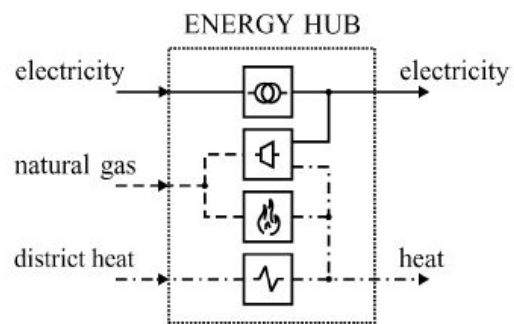


Fig. 2 Energy Hub

본 논문의 구성은 다음과 같다. 2장에서는 일반적인 면역알고리즘에 대해 설명하고, 3장

에서는 널리 사용되고 있는 에너지 허브개념에 면역알고리즘을 적용하여 최적화 하는 시스템을 제안하고자 한다. 마지막 4장에서는 결론 및 연구 방향에 대해 설명한다.

2. 면역 알고리즘

2.1 인체 면역 시스템

면역 시스템은 생체의 방어 및 유지를 수행하는 자율분산 시스템으로, 시스템의 요소들은 뇌의 명령을 따르는 것이 아니라 각 요소가 자율적으로 환경에 대응한다. 생체는 외부로부터 생체 내에 침입한 박테리아, 기생균, 병원균, 독소 바이러스와 같은 항원에 대하여 생체를 방어하기 위해, 세포유전자를 재구성하여 항원(antigen)에 대응하는 항체(antibody)를 생산하고 항원을 배제하는 매우 정교하고 복잡한 생체방어수단인 면역 체계를 가지고 있다. 이 체계는 림프구가 생체 내에서 침입한 항원을 인식하고 그 항원에 대항하는 항체 생성 세포만을 증식한 후, 침입한 항원에 대응하는 항체를 빠르게 만들어 낸다. 그리고 사라지는 항체는 모두 없어지는 것이 아니라, 기억 세포가 되어 면역 기억 세포로 분화한다. 이러한 이론에 바탕으로 면역 알고리즘이 제안되고 있다. 그리고 면역 시스템은 생체 내로 침입한 항원을 인식하고 과거에 배제한 항원에 대해서는 기억세포에서 직접 항체를 만들며, 새로운 항원에 대해서는 세포 유전자의 재구성에 의해 항원에 대응하는 항체생산세포를 만들고 이것을 증식하여 항원에 대응하는 항체를 만든다. 이러한 특성으로 인하여 동일한 항원에 대한 2차 반응은 1차 반응에 비하여 훨씬 빠르고 역동적으로 진행된다 [7]. Fig 3은 면역알고리즘의 예를 보여주고 있다.




Fig. 3 Concept of an immune(antigen-antibody) reaction

2.2 인공면역 알고리즘의 구현

인공면역 (Artificial Immune) 알고리즘은 인체 면역계에서의 다양한 항체 생성 능력을 설명하는 소매틱 이론(somatic theory)과 면역계의 자기 조절 능력을 설명하는 컴퓨팅 기반 네트워크 이론(network hypothesis)을 기초하여 최적화한 알고리즘이다. 인공면역 알고리즘이 다른 일반적인 최적화 알고리즘에 비교하여 다음과 같은 특징을 가진다. 첫째, 면역 알고리즘은 하나의 가능 해를 가지고 최적화 과정을 수행하는 것이 아니라, 동시에 여러 개의 가능 해로써 최적화를 진행해 나간다. 둘째, 해의 값 자체를 그대로 사용하는 것이 아니라, 코드화된 수의 배열을 사용한다. 셋째, 최적화의 목적 함수 값을 사용하며 그 외에 다른 정보를 요구하지 않는다. 이러한 특징은 일반적인 비결정론적 알고리즘인 진화 (Evolution) 알고리즘과도 유사하지만, 면역 알고리즘만이 가지는 가장 큰 특징은 최적 해로의 수렴을 보장하기 위하여 기억 세포군(memory cell)을 가지고 최적화 과정을 수행하며, 이러한 기억 세포군은 다른 항원에 대처할 수 있는 요소로서 사용할 수 있는 특징을 나타낸다[8]. 따라서 면역 알고리즘은 다음과 같이, 3단계로 나타낼 수 있다.

1단계(항원의 인식) - 면역 시스템이 목적

함수와 제한조건 등을 항원으로 정의 한다. 즉 최적화 문제를 정의한다.

2단계(초기 항체군 생성) - 최초의 과정에서 항체를 임의적으로 발생시켜 이들 중에 우수한 항체들을 기억세포에 저장한다.

3단계(친화도(affinity) 계산) - 항원과 항체의 친화도를 계산한다. 친화도의 계산은 항원과 항체간의 친화도로서 최적화 문제로 목적함수와 해와의 관계를 나타낸다. 이것은 진화 알고리즘의 적합도(fitness)를 의미한다. 적합 정도에 따라 새로운 상태로의 전이를 결정할 수 있다.

2.3 학습이론 기반의 면역알고리즘

기본적으로 의사결정 시스템에서 최종결정을 수행하는데 있어, 학습이론이 적용되고 있다. 대표적인 강화학습이론인 Q-learning 알고리즘은 Fig. 4와 같이 구성되어 있다. 이러한 학습이론은 이전 상태와 현재 상태를 고려하여 다음상태를 예측할 수 있도록 도와주고 있다. Fig. 4에서 S는 상태를 나타내고, a는 동작을 의미하며 r은 상태와 동작간의 관계에 따라 환경에 적용되는 상태전이를 의미한다.





Fig. 4 A reinforcement learning theory

특히, 학습이론 개념에 면역알고리즘을 적용하면, 항원과 항체의 친화 정도에 따른 상태 전이를 보다 효율적으로 적용할 수 있어, 다음 Fig. 5와 같이, 구성해서 적용하고자 한다. 여

기에서 항원은 에이전트의 역할을 담당하고, 항체는 환경에 해당하며, 상태와 동작에 따라 복제나 변이가 발생되어 상태가 전이되는 관점이다[9].



- 1) Initialize $Q(s, a)$ to small random values, s, a
- 2) Observe state, s
- 3) Pick an action (stimulus), and do it
- 4) Observe next state, s' , and reward, cloning & mutation
- 5) $Q(s, a) \leftarrow (1 - \alpha)Q(s, a) + \alpha(r + g \max_{a'} Q(s', a'))$
- 6) Go to 2

Fig. 5 Immune Algorithm based on learning theory

3. 면역알고리즘 기반의 MECs (에너지 허브) 시스템

3.1 시스템 구성도

기본적으로 사용되는 에너지 허브 시스템은 Fig. 2에서 보는 바와 같이, 전기, 천연가스, 열 등의 입력이 에너지 허브 시스템 안에서의 정해진 규칙에 따라, 전기 또는 열로 출력되는 시스템이다. 하지만, 본 논문에서 제안하는 면역알고리즘 기반의 에너지 허브 시스템의 경우에는 Fig. 6과 같이, 에너지 허브 시스템 내에 면역알고리즘 기능을 삽입하여 여러 컴포넌트들 (Transformer, Gas Turbine, Gas Furnace, Heat Exchanger)이 자율적으로 학습하고, 학습한 결과에 따라, 전기 또는 열로 출력하는 방식이다. 이는 주변 환경의 변화에 능동적으로 대처하고 이전 환경과 현재 환경 변화에 따라, 다음 환경 변화를 미리 예측하여 출력하는 방식을 결정함으로써 에너지 효율을 증가시킬 수 있는 방법이다. Fig. 6은 인공면역 알

고리즘 기반의 에너지 허브 시스템의 구성도의 단면을 보여주고 있다.

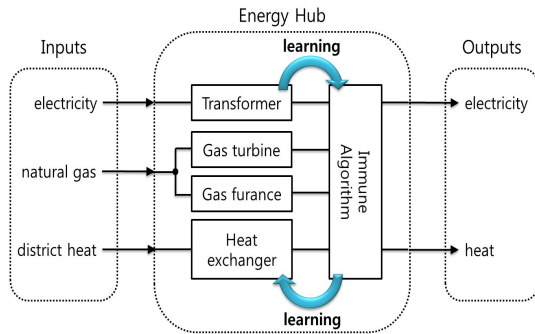


Fig. 6 System Architecture

3.2 자율학습처리

면역 알고리즘 기반의 자율학습처리를 하기 위해서는 Fig. 7과 같이, 자율학습처리 원칙에 따라, 면역알고리즘이 동작되어야 한다. 예로, 초기화된 상태에서 동작된 입력 센서들에 따라, 상태전이를 수행하고, 상태전이에 따라, 최종의사결정이 수행되어야 한다. 특히, 상태 전이를 위해, 이전 상태와 현재 상태의 관계를 Temporal Belief Filtering (TBF)에 따른 예측(Prediction) 값과 실제 측정된 데이터 값의 융합을 통해 학습하고, 학습결과에 따라 갱신 규칙을 적용하는 방식이다.

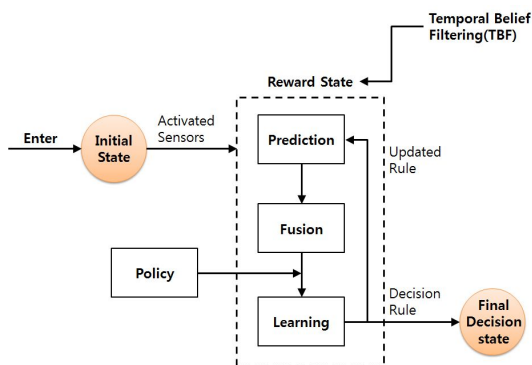


Fig. 7 Self-learning process principle

첫째, TBF는 연속적인 두 상태변화를 측정하기 위해, 우선 각각의 상태마다 발생하는 센서들의 동작들은 정확하다고 가정한다. 또한 이전 상태와 현재 상태의 확실적인 정확도는 특별한 동작 센서들의 변화 없이는 크게 변화가 없다고 초기 가정한다.

둘째, 상태전이를 측정하기 위해서, 먼저 예측을 수행한다. 입력되는 내용에 따라, 선택되어지는 컴포넌트들은 고유동작 범위를 가지고 있다. 이때, 이전상태의 값과 진화정도의 결합 법칙에 따라 식(1)과 같이, 현 상태를 예측할 수 있다. 여기서 $\hat{m}_{t,M}^{\Theta}$ 는 예측(Prediction)을 나타내고, m_{t-1}^{Θ} 는 이전상태 값을 나타내며, m_M^{Θ} 는 진화정도를 의미하며, (M_U) 는 결합 법칙을 의미한다.

$$\hat{m}_{t,M}^{\Theta} = m_{t-1}^{\Theta} (M_U) m_M^{\Theta} \dots\dots\dots(1)$$

셋째, 실제 입력센서 동작으로 인해 측정된 컴포넌트들의 동작의 신뢰도를 높이기 위해, 예측된 컴포넌트들의 동작범위와 측정된 센서 동작을 식(2)와 같이 융합한다. 이때, 정해진 정책에 따라, 오차범위를 설정하고 오차범위가 기준점 보다 클 경우에는, 새로운 상태변이가 적용되고, 오차범위가 기준점보다 작을 경우에는 이전 상태의 결과에 따라, 컴포넌트들이 동작하도록 한다. $m_{t,M}^{\Theta}$ 는 상태전이를 의미하고, $\hat{m}_{t,M}^{\Theta}$ 는 예측 값을 나타내고, m_t^{Θ} 는 현 상태에서 측정된 값을 나타내며, (M_{Γ}) 는 교환법칙을 의미하고, $m_{t-1,M}^{\Theta}$ 는 상태전이 없이 이전 상태의 값을 의미한다. 또한, $C_F \geq T$ 는 오차범위가 기준점보다 크다는 것을 나타내고, $C_F < T$ 는 오차범위가 기준점보다 작다

는 것을 의미한다.

$$m_{t,M}^{\ominus} = \begin{cases} \hat{m}_{t,M}^{\ominus} & (M_{\cap}) \\ m_t^{\ominus}, & \text{if } C_F \geq T \\ m_{t-1,M}^{\ominus} & , \text{if } C_F < T \end{cases} \dots (2)$$

마지막으로, 상태전이에서 학습을 적용하기 위해, a fading memory process(F_a)가 적용되어, 최근의 상태전이만 고려하고, 오래된 상태 전이에 대한 데이터는 적용하지 않아, 상태에 따른 예측하고 측정된 데이터의 융합 신뢰도를 높일 수 있다. 식(3)은 정해진 타임 슬롯(W)에 따른 (F_a) 적용방법을 보여주고 있다.

여기에서 $m_{t+w,M}^{\ominus}$ 는 타임슬롯이 적용된 상태전이를 나타내며, 만약 W 가 일정한 상수값 $C=5$ 를 가지면, 타임슬롯을 현 시점을 기준으로 이전 상태 4개까지 고려한다는 의미이다. 그리고 상태변화의 정도는 계속 누적되는 것이 아니라, 다시 0으로 초기화되고 예측 상태 값과 현재 상태 값이 같다고 다시 초기화 한다. 즉, (F_a)가 적용된 후, 갱신규칙에 상태전이 결과값이 적용되고, 그 결과 값에 따라, 최종 의사결정을 진행할 수 있다.

$$m_{t+w,M}^{\ominus} = \begin{cases} (1) F_a \leftarrow \begin{cases} \sum C_F = 0 & , \text{if } W = C \\ \hat{m}_{t+w,M}^{\ominus} = m_{t+w}^{\ominus} \end{cases} \\ (2) m_{t,M}^{\ominus} \times (F_a) \end{cases} \quad (3)$$

3.3 자율학습처리 기반 인공지능 알고리즘 적용의 예

인공지능알고리즘 기반 에너지 허브 시스템을 실험하기 위해, 기상 조건에 따라 에너지 허브 내의 컴포넌트들이 Fig. 8과 같이, 동작한다고 가정하였다. 특히, 기상 악화로 태양의 일조량이 부족한 경우라고 가정하고, 입력들이 상태전이 상태에서 Gas Furnance나 Heat Exchanger

로 변화하여, 전기 또는 열로 출력되는 것을 가정하였다.

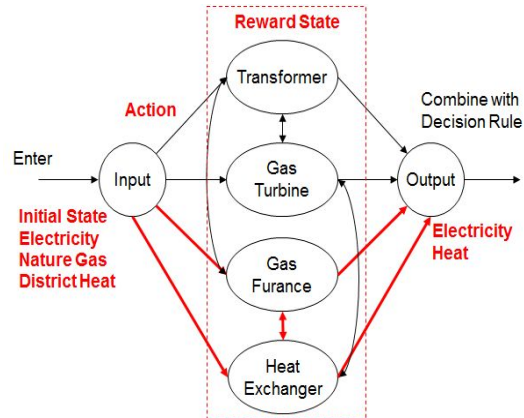


Fig. 8 The initial energy hub system based on immune algorithm

약 3000번의 테스트 결과, Fig. 9와 같이, 실험결과가 나왔다. 반복적인 학습을 통해, 스스로 컴포넌트를 선택해서 동작횟수의 빈도가 증가하는 것을 볼 수 있다. 즉, 초기상태와 상관된 예측시스템의 동작으로 보다 예상되는 시스템의 동작방향성이 정해질 수 있는 모습을 확인 할 수 있다.

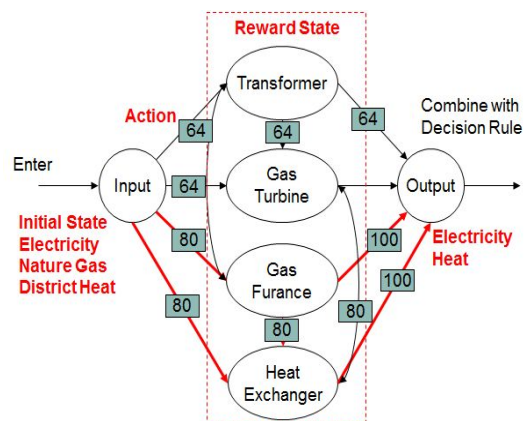


Fig. 9 Energy hub system after immune algorithm application

4. 결 론

지금까지 면역 알고리즘 기반의 에너지 허브 시스템에 대해서 알아보았다. 대표적인 MAGA 시스템과 달리, 상태전이 상태에서 이전상태와 현 상태의 값을 융합하여 예측상태를 만들고, 각각의 컴포넌트들이 예측상태에 따라, 스스로 변화해서 적응할 수 있는 시스템을 구성하고자 하였다. 특히, 기존의 강화학습 알고리즘에 인공면역 알고리즘을 적용하고, 예측, 융합, 학습을 수행할 수 있는 TBF 알고리즘을 적용하여 시간 변화에 따라 적응할 수 있는 에너지 허브 시스템을 구성하였다. 시뮬레이션으로 약 3000번의 학습을 통해, 초기의 값에 따라 상태전이 정도가 변화된 것을 확인하였다. 하지만, 실제 에너지 허브에 영향을 미치는 환경적 변수는 아직 적용하지 못하고, 기본적인 입력 센서 값이 정확하다는 가정 하에, 에너지 허브 시스템 내의 컴포넌트의 고유 영역 값들의 변화만을 통한 출력결정을 하였다. 따라서 추후 연구방향으로 환경적 변수를 고려하여, RTDS 기반으로 실시간 실험을 수행하고, 똑같은 조건으로 MAGA 시스템과 비교분석하고자 한다.

후 기

본 연구는 미래창조과학부에서 지원하는 대구경북과학기술원 기관일반사업에 의해 수행되었습니다(14-BD-01).

This work was supported by the DGIST R&D Program of the Ministry of Science, ICT and Future Planning of Korea(14-BD-01).

Reference

1. Wooseok Seo and Moonseog Jun, A Direction of Convergence and Security of Smart Grid and Information Communication Network, KIECS, Vol. 5, No. 5, pp. 477~486, 2010
2. Ashrae, ASHRAE Handbook 1993 Fundamentals, ASHRAE, 1993
3. Givoni, Baruch, Climate Considerations in Building and Urban Design, Van Nostrand Reinhold, 1998
4. Krause, T., Andersson, G., Frohlich and K., Vaccaro, A., Multiple-Energy Carriers : Modeling of Production, Delivery, and Consumption, PROCEEDINGS OF THE IEEE, Vol. 99, No.1, pp. 15~27, 2011
5. Moeini-Aghtatie, M., Dehghanian, P. Fotuhi-Firuzabad and M. Abbaspour, Multitagent Genetic Algorithm : An Online Probabilistic View on Economic Dispatch of Energy Hubs Constrained by Wind Availability, IEEE TRANSACTIONS ON SUSTAINABLE ENERGY, Vol. 5, Issue 2, pp. 699~708, 2014
6. Payman Dehghanian, Seyed Hamid Hosseini, Moein Moeini-Aghaie and Amirsaman Arabali, Optimal siting of DG units in power systems form a probabilistic multi-objective optimization perspective, Int. J. Elect. Power Energy Syst., Vol. 51, pp. 14~26, 2013
7. Jae-Hoon Cho, Dong-Hwa Kim and Sung-Kwun Oh, Fuzz-Neural Networks by Means of Advanced Clonal Selection of Immune Algorithm and Its Application to Traffic Route Choice, Korean Institute of Intelligent Systems, Vol. 14, No. 4, pp. 402~410, 2004
8. U. Aickelin and D. Dasgupta, ARTIFICIAL IMMUNE SYSTEMS, Search Methodologies : Introductory Tutorials in Optimization and Decision Support Techniques, 2008
9. NAHUM SHIMKIN, Reinforcement Learning - Basic Algorithms, LEARNING IN COMPLEX SYSTEMS LECTURE NOTES, pp. 1~16, 2011