

# 유전 알고리듬을 이용한 연속 공정의 최적 제어

## Optimal Control of Continuous System Using Genetic Algorithms

이무호, 한종훈, 장근수  
(Moo Ho Lee, Chonghun Han and Kun Soo Chang)

**Abstract :** The optimal control of a continuous process has been performed using genetic algorithms(GAs). GAs are robust and easily applicable for complex and highly nonlinear problems. We introduce the heuristics 'dynamic range' which reduces the search space dramatically keeping the robust search of GAs. GAs with dynamic range show the better performance than SQP(Successive Quadratic Programming) method which converges to a local minimum. The proposed methodology has been applied to the optimal control of the continuous MMA-VA copolymerization reactor for the production of the desired molecular weight and the composition of VA in dead copolymer.

**Keywords:** genetic algorithms, optimal control, copolymerization, SQP

### I. 서론

최근 화학 공정의 가장 큰 과제들 중 하나는 다양한 소비자의 욕구 충족을 만족시킬 수 있는 고품질의 다양한 제품을 얼마나 경제적으로 생산하느냐하는 것이다. 일반적으로 단품종 생산을 위해서는 회분식 반응기(batch reactor)가 적합하나 생산 양이 많은 경우는 생산 조건, 즉 조업 조건을 바꾸어 한 연속 공정(continuous process)으로부터 사양이 다른 여러 종류의 제품들을 생산하는 사양 변경 조업(grade change operation)으로 생산할 수 있다. 실제로 현장에서는 기존에 설치되어 운전중인 연속 공정을 전용하여 사양이 다른 여러 종류의 제품을 생산하는 사양 변경 조업을 하기도 한다[1, 12].

연속 공정에서 개시 조업(start-up operation)이나 사양 변경 조업의 경우 정상 상태(steady state)에 도달하기 전까지 생산된 제품은 원하는 사양을 갖추지 못하게 되어 쌍값에 판매하거나 폐기 처분하고 있다. 연속 공정에서 원하는 정상상태에 도달하는데 필요한 시간을 전환시간(transition time)이라고 한다. 그러므로 이 전환시간을 최소로 하면서 원하는 사양의 제품을 얻는 문제는 생산성 향상에 매우 중요하다고 할 수 있다. 예로 연속 고분자 중합 반응기의 경우 조업 전환 시간이 20~30시간이 되므로 전문 조업자의 경험에 의존하여 전환시간을 단축시키고자 하는 많은 시도가 행해지고 있다. 그러나 조업 전문가가 공정의 출력을 살피면서 입력을 조금씩 바꾸어 주는 방법은 시간과 노력에 있어 낭비의 요소가 있으며 이렇게 구한 조업 조건들이 최상이라는 것을 보장할 수 없기 때문에 보다 체계적인 접근방법인 최적 제어 기법이 요구된다. 연속 공정에서의 최적 제어란 가능한 한 짧은 시간안에 원하는 물성을 만족시키는 정상상태에 도달시킬 수 있는 제어 입력 케이스를 구하는 것이다.

기존의 최적 제어 방법들로는 dynamic programming이나 Pontryagin의 minimum principle이 대표적이다. Dynamic programming은 광역의 최적값(global optimum)을 보장하나 문제의 크기가 커질 경우 계산 시간이 기하급수적

으로 증가하므로 적용 대상이 작은 문제로 제한되는 단점이 있다[3]. minimum principle를 적용하면 상태, 보조 미분방정식을 구성하게 되는데 이를 수치적으로 풀어주는데 많은 계산 시간이 소요되므로 상태 변수와 제어 입력 변수의 개수가 많고 모델 수식과 목적함수가 복잡한 경우 적용하기가 힘든 단점이 있다. 고분자 반응기의 최적 제어 문제에 minimum principle를 이용한 연구가 많이 발표되었으나[7, 10] 대부분의 연구는 수식 모델이 공중합반응(copolymerization)보다 간단한 회분식 반응기(batch reactor)에서의 단일중합반응(homopolymerization)에 대한 연구로 원하는 분자량과 전환율을 얻기 위한 최적 온도 케이스를 구하였다.

적용의 용이성과 강건한 탐색 특성으로 복잡한 비선형 시스템의 최적화에 적합한 유전 알고리듬(genetic algorithms)은 여러 종류의 최적화 문제에 적용되어 좋은 결과를 주었다[4, 9, 11].

본 연구에서는 복잡한 비선형 연속 공정의 최적 제어를 위해 유동 탐색 구간(dynamic range)을 갖는 유전 알고리듬을 제안하고 이 방법을 연속 methyl methacrylate(MMA)-vinyl acetate(VA) 공중합 반응기의 최적 제어에 적용하였다.

### II. 유전 알고리듬

#### 1. 유전 알고리듬의 특징

탐색 속도와 장인성의 상호 절충을 통해 나온 방법이 무작위 탐색에 의한 방법들이다. 그러나 무작위 탐색 방법은 장인성에 대한 보상으로 탐색 효율이 떨어지는 단점이 있다. 유전알고리듬도 무작위 탐색 방법을 사용하고 있지만 중요한 차이점은 방향성이 있는 탐색으로 무작위 탐색보다는 속도가 빠르며 기존의 gradient-based method보다는 탐색 속도가 느려도 장인성이 있어 광역의 해를 찾을 가능성이 높은 특징을 가지고 있다. 반면 무작위 탐색을 하므로 광역의 해에 접근해서도 정확한 최적값으로 수렴하는데는 상당한 시간이 걸리는 단점이 있다.

유전 알고리듬은 일반적인 최적화 방법에 비해 몇 가지 차이점을 가지고 있다. 첫째가 최적화를 위해 인자 자체를 이용하지 않고 인자 코드를 사용한다. 둘째는 한 점만을 이용한 최적화가 아니라 여러 개의 인자열을 이용해 동시에 탐색을 한다는 것이고 셋째는 최적화를 위해 목적함수의 미분값 등 수학적 전개를 필요로 하지 않고 단지 목적 함수값만을 이용한다. 넷째는 인과적인(deterministic gradient)인

접수일자 : 1996. 6. 24., 수정완료 : 1996. 11. 15.

이무호, 한종훈, 장근수 : 포항공과대학교 화학공학과, 지능자동화 연구센터

\* 본 논문은 한국과학재단 지정 우수연구센터인 공정산업의 지능 자동화 연구센터와 교육부 지정 포항공과대학교 환경공학부에서 지원하여 연구하였습니다.

방법이 아니라 확률적인 전이(probabilistic transition)를 이용한다. 이러한 특징들은 공중합 반응기의 수식 모델처럼 복잡하고 심한 비선형성을 가지며 제어 입력에 제한이 있고 탐색 범위가 넓은 경우에도 적합하다[2].

## 2. 단순 유전 알고리듬(Simple Genetic Algorithms)

유전 알고리듬은 그 동안 많은 발전을 하여 향상된 연산자들이 개발되었으며 각각의 문제에 맞도록 설계된 특수 연산자들도 등장하였다[11]. 그렇지만 단지 인자 코드를 복제하고 부분적으로 교배시키고 확률적으로 돌연변이를 일으켜 주어 보다 나은 개체를 생산하는 단순 유전 알고리듬은 아직도 유전 알고리듬의 근간을 이루고 있으며 실제의 많은 문제에 적용되어 좋은 결과를 주고 있다[4, 9]. 유전 알고리듬의 기본적인 연산자는 재생산, 교배, 돌연변이이다.

재생산(reproduction)이란 현세대 즉 현재의 탐색 상태를 고려해 주어 더 좋은 탐색으로 진행하기 위한 다음 세대의 구성을 말한다. 현세대의 어떤 유전 인자열을 다음 세대에 얼마나 재생산하느냐는 그 유전 인자열에 의해 결정되는 목적 함수값의 크기에 의해 정해진다. 그러므로 탐색 목적을 잘 만족시키는 유전 인자열 즉 우성 인자열은 다음 세대에 많이 재생산되며 열성 인자열은 상대적으로 도태되게 된다. 세대가 진행된다는 것은 일반적인 최적화 알고리듬에서 최적화 과정의 반복 횟수(iteration number)에 해당된다. 결과적으로 세대가 진행될수록 적자 생존의 원칙에 의하여 우성 인자들만이 살아남게 된다.

단순히 재생산만을 한다면 현 세대의 우성인 인자열보다 더 뛰어난 인자열을 다음 세대에서 찾을 수가 없게 된다. 그러므로 우성인 인자열을 찾기 위해서 재생산된 인자열들 간의 교배(crossover)를 행하게 된다. 교배는 먼저 재생산된 인자열들 중에서 무작위로 교배될 두 개의 인자들을 선택한다. 역시 무작위로 선택된 인자열들의 교배 위치를 정하여 교배를 시켜 준다. 교배는 그림 1(a)처럼 두 인자열의 인자(code)들을 서로 교환하는 것이다. 이 과정을 거쳐 만들어진 새로운 인자열은 다음 세대를 위한 재생산 과정에서 우성인지 열성인지 판정받게 된다. 이런 과정을 통해 세대를 거듭하면서 새로운 우성인 인자를 찾아내는 효과를 기울 수 있다.

전 단계의 재생산이나 교배는 처음 주어진 인자열을 가지고 계속 연산을 하게 된다. 이런 경우 전 세대와 비슷한 인자열을 가지고 다음 세대를 만들기 때문에 지역적인 극소값에 빠질 우려가 있다. 이러한 점을 보완하기 위한 것이 돌연변이 연산자이다. 돌연변이(mutation) 연산은 그림 1(b)처럼 인자열의 한 인자를 무작위로 정하여 주어진 돌연변이 발생 확률에 따라 정해진 인자의 성질을 바꾸어 주는 것이다. 인자가 이진수인 경우 1이면 0으로 0이면 1로 바꿔주게 된다. 교배와 마찬가지로 돌연변이를 일으킨 인자열이 다음 세대에 우성으로 많이 재생산된다면 돌연변이가 지역적 극소값에서 벗어나는데 중요한 역할을 하게 된다.

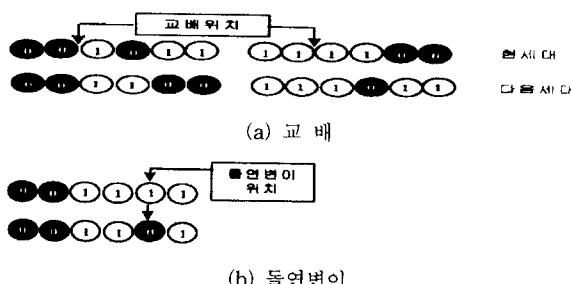


그림 1. 유전알고리듬의 교배와 돌연변이 연산자.  
Fig. 1. Crossover and mutation operator in GAs.

## III. 유전 알고리듬을 이용한 최적 시간 제어

연속 공정을 위한 최적 제어 문제는 일반적으로 다음과 나타낼 수 있다.

$$\begin{aligned} \text{Min. } J &= h(x(t_i), t_i) + \int_{t_0}^{t_f} g(x(t), u(t), t) dt \quad (1) \\ \frac{dx}{dt} &= f(x(t), u(t), t), \quad x(t_0) = x_0 \quad (2) \end{aligned}$$

$$u_{i,\min}(t) \leq u_i(t) \leq u_{i,\max}(t) \quad (3)$$

최적 제어는 목적 함수(1)를 최소화하도록 제어입력의 궤적,  $u_i(t)$ 을 구해주는 것이다. 이러한 최적 제어 문제는 전체 전환시간을 각 구간 내에서 일정한 제어 입력값을 갖는 몇 개의 구간으로 나누어 제어 목적을 만족시키도록 각 구간에 해당하는 제어 입력값들을 찾는 최적화 문제로 전환할 수 있다. 이때  $m$ 개의 제어입력변수를 각각  $n$ 개로 나누어 줄 경우 다음과 같이 나타낸다.

$$u_{i,\min}^j \leq u_i^j \leq u_{i,\max}^j, \quad i=1, \dots, m, \quad j=1, \dots, n \quad (4)$$

그러므로 위의 최적 제어 문제는  $m \times n$ 개의 최적화 변수를 갖는 최적화 문제로 전환된다.

유전알고리듬의 적용을 위해 각 구간의 제어 입력값들을 유전 알고리듬의 인자열로 할당한다. 유전알고리듬은 제어 입력 변수의 형태와 제약에 관계없이 적용이 용이하고 강건하지만 본 문제처럼 구간이 여럿인 경우는 최적화 변수가 너무 많아져 수렴이 어렵고 달성한 결과도 좋지 않게 된다. 이러한 단점을 극복하고 정상 상태에 빠르게 도달하게 하기 위해서는 유전 알고리듬의 강건성을 떨어뜨리지 않으면서 탐색 속도를 높일 수 있는 적절한 가정을 도입하여야 한다. 정상 상태의 도달과 빠른 수렴 속도를 얻기 위해서는 반응 초기에는 제어 입력 구간을 넓게하여 여러 가지 최적화 경로를 고려해 주고 시간이 지날수록 구간을 점진적으로 줄여 주어야 한다. 이러한 가정을 이용해 반응 시간이 지남에 따라 각 제어 입력값이 가질 수 있는 구간을 전단계에서 구한 정상 상태의 제어 입력값을 기준으로 점차적으로 줄여 주었다. 이러한 방법을 유동 탐색 구간(dynamic range)방법이라고 하여 다음과 같이 구현하였다. 전단계로 먼저 충분히 긴 전환시간 동안 일정한 제어 입력값을 주면 정상상태에 도달하게 되는데, 이렇게 도달한 정상상태가 원하는 물성을 줄 수 있도록 제어 입력값을 유전알고리듬으로 찾아 준다. 구한 제어입력값을 정상상태의 제어입력값이라고 하고 정상상태의 도달 시간을 다음 단계의 전환시간으로 사용한다. 첫 번째 제어 입력값은 원래 조작 변수가 가질 수 있는 구간을 갖게 되고 두 번째 제어 입력값은 정상 상태의 제어 입력값을 기준으로 첫 번째 입력값보다는 좁은 구간을 갖게 된다. 세 번째 입력값도 마찬가지로 정상 상태값을 중심으로 두 번째 입력값보다 좁은 구간을 갖게 된다. 일반적으로 최적 제어에서 전환 시간을 줄일 경우에는 전환 시간 또한 최적화 변수가 되지만 본 연구에서는 원하는 정상 상태가 항상 보장되므로 위의 최적화 목적 함수만을 최소화 해도 전환시간이 단축되기 때문에 전환 시간을 변수로 고려해 주지 않았다.

## IV. 연속 MMA-VA공중합 공정과 유전 알고리듬의 적용

### 1. 연속 MMA-VA 공중합 공정 및 수식 모델

연속 MMA-VA공중합 공정은 두 종류의 모노미인 MMA와 VA, initiator, solvent, chain transfer agent, inhibitor가 입력으로 들어가며 온도 제어를 위해 heat jacket이 달려 있다. 이러한 공중합 공정의 수식 모델은 복잡하고

심한 비선형성을 갖는 미분방정식으로 표현된다. 연속 MMA-VA 공중합 공정의 모델식과 속도 상수, 공정 조건은 Congalidis 등이 모델링한 다음과 같은 수식 모델을 사용하였다[6].

물질수지식

$$\frac{dC_k}{dt} = \frac{C_{k0} - C_k}{\theta_r} - R_k \quad (5)$$

$$C_k(0) = C_{k0}, \quad k = \text{MMA, VA, initiator, solvent, chaintransferagent, inhibitor} \quad (6)$$

속도 상수식

$$R_a = [(k_{paa} + k_{xaa})C_a + (k_{pba} + k_{xba})C_b]C_a \quad (7)$$

$$R_b = [(k_{pbb} + k_{xbb})C_b + (k_{pab} + k_{xab})C_a]C_b \quad (8)$$

$$R_i = k_i C_i \quad (9)$$

$$R_t = [k_{xat}C_a + k_{xbt}C_b]C_t \quad (10)$$

$$R_s = [k_{xas}C_a + k_{xbs}C_b]C_s \quad (11)$$

$$R_z = [k_{xaz}C_a + k_{xbz}C_b]C_z \quad (12)$$

a=MMA, b=VA, I=initiator, s=solvent, t=chain transfer agent, z=inhibitor

$$C_a \cdot = \frac{-l_2 + \sqrt{l_2^2 - 4l_1l_3}}{2l_1}, \quad C_b \cdot = \beta \cdot C_a \quad (13)$$

$$\beta = \frac{k_{pab} + k_{xab}}{(k_{pba} + k_{xba})C_a} \quad (14)$$

$$l_1 = k_{caa} + k_{daa} + 2\beta(k_{cab} + k_{dab}) + \beta^2(k_{cbb} + k_{dbb}) \quad (15)$$

$$l_2 = C_z(k_{za} + \beta k_{zb}) \quad (16)$$

$$l_3 = -2k_i C_i e \quad (17)$$

고분자에서의 VA의 조성

$\lambda_a, \lambda_b$ : Concentration of Two Monomer of Dead Copolymer.

$$Y_{VA} = \frac{\lambda_a}{\lambda_a + \lambda_b} \quad (18)$$

$$\frac{d\lambda_a}{dt} = \frac{\lambda_{af} - \lambda_a}{\theta_r} + R_a, \quad \lambda_a(0) = \lambda_{a0} \quad (19)$$

$$\frac{d\lambda_b}{dt} = \frac{d\lambda_{bf} - \lambda_b}{\theta_r} + R_b, \quad \lambda_b(0) = \lambda_{b0} \quad (20)$$

수 평균, 무게 평균 분자량

$M_n$  : 수 평균 분자량,  $M_w$  : 무게 평균 분자량.

$$M_n = \frac{\psi_1^p}{\psi_0^p}, \quad M_w = \frac{\psi_2^p}{\psi_1^p} \quad (21)$$

고분자의 분자량 분포 모멘트(moment)

$\psi_0^p, \psi_1^p, \psi_2^p$ : Zero, First, Second Moment of Dead Copolymer.

$$\frac{d\psi_0^p}{dt} = \frac{\psi_1^p - \psi_0^p}{\theta_r} + \frac{1}{2} k_{caa}(\psi_0^p)^2 + k_{cab}\psi_0^p\psi_1^p + \frac{1}{2} k_{cbb}(\psi_0^p)^2 + L_1\psi_0^p + L_2\psi_0^p \quad (22)$$

$$\frac{d\psi_1^p}{dt} = \frac{\psi_2^p - \psi_1^p}{\theta_r} + k_{caa}\psi_0^p\psi_1^p + k_{cab}(\psi_0^p\psi_1^p + \psi_0^p\psi_1^p) + k_{cbb}\psi_0^p\psi_1^p + L_1\psi_1^p + L_2\psi_1^p \quad (23)$$

$$\frac{d\psi_2^p}{dt} = \frac{\psi_2^p - \psi_1^p}{\theta_r} + k_{caa}[(\psi_1^p)^2 + \psi_0^p\psi_1^p] + k_{cab}(2\psi_1^p\psi_1^p + \psi_0^p\psi_1^p + \psi_2^p\psi_1^p) + k_{cbb}[(\psi_1^p)^2 + \psi_0^p\psi_1^p] + L_1\psi_1^p + L_2\psi_1^p \quad (24)$$

$$\psi_0^p(0) = \psi_{00}^p, \quad \psi_1^p(0) = \psi_{10}^p, \quad \psi_2^p(0) = \psi_{20}^p \quad (25)$$

$$L_1 = k_{xas}C_s + k_{xaa}C_a + k_{xab}C_b + k_{xat}C_t + k_{za}C_z + k_{daa}C_a + k_{dab}C_b \quad (26)$$

$$L_2 = k_{xbs}C_s + k_{xbb}C_b + k_{xta}C_a + k_{xtb}C_t + k_{zb}C_z + k_{dbb}C_b + k_{dab}C_a \quad (27)$$

활성고분자(living copolymer)의 분자량 분포 모멘트

$\phi_0^a, \phi_1^a, \phi_2^a, \psi_0^b, \psi_1^b, \psi_2^b$ : Zero, First, Second Moment of Live Copolymer

$$\phi_0^a = \frac{B_3}{B_1} \quad (28)$$

$$\phi_1^a = \frac{\alpha_1\alpha_2 V_1(M_b + M_a) + \alpha_1 C_1 M_a}{B_1} - \frac{B_2 B_3}{B_1^2} \quad (29)$$

$$\phi_2^a = \frac{-B_3[(\alpha_1 + \alpha_2)M_a M_b + B_2(M_a + M_b - 1)]}{B_1^2} + \phi_1^a + \frac{\alpha_1\alpha_2 V_1(M_a + M_b - 1)(M_a + M_b)}{B_1} + \frac{\alpha_1 C_1 M_a (M_a - 1)}{B_1} + \frac{2B_2^2 B_3}{B_1^3} \\ - \frac{2B_2[\alpha_1\alpha_2 V_1(M_a + M_b) + \alpha_1 C_1 M_a]}{B_1^2} \quad (30)$$

$$\phi_0^b = \frac{B_4}{B_1} \quad (31)$$

$$\phi_1^b = \frac{\alpha_1\alpha_2 V_1(M_b + M_a) + \alpha_2 C_4 M_b}{B_1} \quad (32)$$

$$\phi_2^b = \frac{-B_4[(\alpha_1 + \alpha_2)M_a M_b + B_2(M_a + M_b - 1)]}{B_1^2} + \phi_1^b + \frac{\alpha_1\alpha_2 V_2(M_a + M_b - 1)(M_a + M_b)}{B_1} + \frac{\alpha_2 C_4 M_b (M_b - 1)}{B_1} + \frac{2B_2^2 B_4}{B_1^3} \\ - \frac{2B_2[\alpha_1\alpha_2 V_2(M_a + M_b) + \alpha_2 C_4 M_b]}{B_1^2} \quad (33)$$

$$\alpha_1 = k_{caa}C_a / ((k_{caa} + k_{daa})C_a + (k_{cab} + k_{dab})C_b + (k_{daa} + k_{xaa})C_a + (k_{pab} + k_{xab})C_b + k_{xat}C_t + k_{xas}C_s + k_{za}C_z) \quad (34)$$

$$\alpha_2 = k_{pbb}C_b / ((k_{cbb} + k_{dbb})C_b + (k_{cab} + k_{dab})C_a + (k_{pbb} + k_{xbb})C_b + (k_{pba} + k_{xba})C_b + k_{xbt}C_t + k_{xbs}C_s + k_{zb}C_z) \quad (35)$$

$$C_1 = \frac{2k_{ie}C_i + C_s(k_{xas}C_a + k_{xbs}C_b)}{k_{paa}(C_a + C_b)} + \frac{C_t(k_{xat}C_a + k_{xbt}C_b)}{k_{paa}(C_a + C_b)} + \frac{(k_{xaa}C_a + k_{xba}C_b)}{k_{paa}} \quad (36)$$

$$C_4 = \frac{2k_{ie}C_i + C_s(k_{xas}C_a + k_{xbs}C_b)}{k_{pbb}(C_a + C_b)} + \frac{C_t(k_{xat}C_a + k_{xbt}C_b)}{k_{pbb}(C_a + C_b)} + \frac{(k_{xbb}C_a + k_{xba}C_b)}{k_{pbb}} \quad (37)$$

$$\gamma_1 = \frac{k_{paa}}{k_{pab}}, \quad \gamma_2 = \frac{k_{pbb}}{k_{pba}}, \quad \gamma = \frac{k_{pba}}{k_{pab}} \quad (38)$$

$$c_2 = c_4\gamma_2\gamma, \quad c_3 = \frac{c_1\gamma_1}{\gamma}, \quad x = \frac{1}{\gamma_1\gamma_2} \quad (39)$$

$$V_1 = c_2x - c_1, \quad V_2 = c_3x - c_4 \quad (40)$$

## 2. 공중합 공정에서의 최적 제어와 유전 알고리듬

고분자 공정, 특히 공중합 반응의 경우 복잡한 반응 메커니즘으로 인해 모델식이 복잡하고 비선형성이 강해 해석과 제어가 어려운 대표적인 공정으로 인식되고 있다. 이러한 공중합 반응기의 최적 제어에 유전 알고리듬이 적합한 몇 가지 이유가 있다. 첫째, 본 공정의 경우 원하는 물성인 무게 평균 분자량과 VA의 조성이 여러 공정 변수의 복잡한 비선형식으로 표현되므로 단순히 최종 목적 함수값만을 필요로 하는 유전 알고리듬이 적합하다. 둘째, 원하는 물성을 효율적으로 얻기 위해 시간에 따른 두 종류의 제어 입력을 사용하고 있어 탐색 영역이 넓어져 광역 최적해를 찾는데 실패할 확률이 높으므로 강건한 유전 알고리듬이 적합하다.

셋째, 빠르게 원하는 정상 상태에 도달하게 하기 위해서는 정상 상태의 정보를 이용하여 반응 시간이 지날수록 제어 입력값이 가질 수 있는 값의 구간을 한정해야 하는데 유전 알고리듬은 쉽게 제어 입력값의 구간을 제한할 수 있는 장점을 가지고 있다.

### 3. 유전 알고리듬을 이용한 공중합 반응기의 최적 제어

공중합 반응기에서 최적 제어의 목적은 가능한 짧은 전환 시간에 원하는 분자량과 모노머의 조성을 만족시키는 정상상태에 도달하게 하는 제어입력의 궤적을 구하는 것이다. 그러므로 최적 제어 목적 함수를 다음과 같이 나타내었다.

$$\text{Min. } J = \int_{t_0}^{t_f} (w_1 |M_{ud} - M_w(t)| + w_2 |Y_{VAd} - Y_{VA}(t)|) dt \quad (41)$$

$$298.15 \leq u_1 \leq 373.15, \quad 20 \leq u_2 \leq 200 \quad (42)$$

(41)에서  $w_1$ 과  $w_2$ 는 가중치로  $M_w$ 와  $Y_{VA}$ 의 단위가 다르므로 비슷한 정도로 목적함수에 작용하게 하기 위해 시뮬레이션을 통해  $w_1=1.0$ ,  $w_2=100,000$ 으로 정하였다. 달성하기 원하는 분자량과 고분자 내에서의 VA의 조성을  $M_{w,d}=80,000$ ,  $Y_{VA,d}=0.20$ 으로 잡아 주었으며 조작 변수는 heat jacket의 온도(K)와 VA의 유량(kg/hr)으로 정하였다.

최적화의 전 단계로 원하는 정상 상태를 달성할 수 있는 두 제어 입력값과 도달 시간을 유전 알고리듬을 사용하여 쉽게 구하였다. 정상 상태에 도달하기까지의 전체 반응시간을 150,000초로 정하여 이를 1500번으로 나누어 한 간격이 10,000초가 되게 잡아 주었다. 제어 입력 변수가 두 개 있으므로 두 제어 입력 변수들의 궤적을 나타내기 위해 30개의 제어 입력값들을 갖는 인자열을 만들었다. 유전 알고리듬 성능에 영향을 미치는 인자열의 수(P), 교배율(C)과 돌연변이율(M)을 DeJong[5]과 Grefenstette[8]가 구한 결과를 참고하여 시뮬레이션을 통해 그림 2, 3, 4와 표 1과 같이 구하였다.

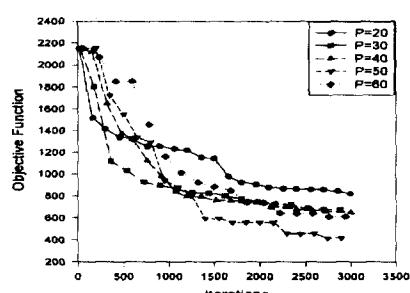


그림 2. 인자열수에 따른 목적함수값의 변화( $C=0.6$ ,  $M=0.0001$ ).

Fig. 2. Control objective for different population size, at  $C=0.6$  and  $M=0.001$ .

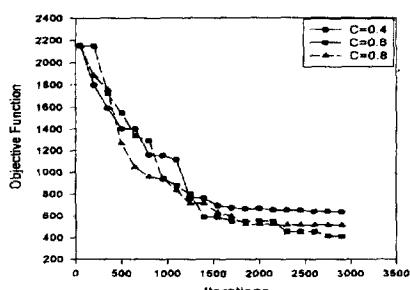


그림 3. 교배율에 따른 목적함수값의 변화( $P=50$ ,  $M=0.001$ ).

Fig. 3. Control objective for different crossover rate at  $P=50$  and  $M=0.001$ .

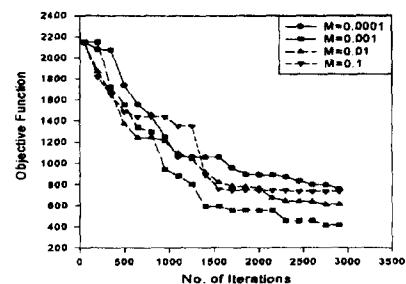


그림 4. 돌연변이율에 따른 목적함수값의 변화 ( $P=50$ ,  $C=0.6$ ).

Fig. 4. Control objective for different mutation rate at  $P=50$  and  $C=0.6$ .

표 1. 유전알고리듬을 위한 조건들.

Table 1. Conditions for genetic algorithms.

	인자열개수	교배율	돌연변이율
DeJong	50-100	0.6	0.001
Grefenstette	30	0.95	0.01
Ours	50	0.6	0.001

유전알고리듬과 기존의 비선형 최적화 기법의 장단점을 비교하기 위해 앞에서 구한 유전알고리듬의 조건으로 최적 제어한 결과와 비선형 최적화에 널리 쓰이고 있는 SQP (Successive Quadratic Programming)를 사용한 결과를 표 2에 정리하였다. SQP의 경우 초기 조건에 따라 최적화 결과가 큰 영향을 받으므로 10개의 서로 다른 초기 조건으로 최적화한 결과를 가장 좋은 것, 가장 나쁜 것, 평균으로 구분해 나타내었다. SQP의 경우 지역적 극소값에 빠지면 나오지 못하는 단점으로 인해 좋은 결과를 주지 못하였으나 유전 알고리듬의 경우는 반복 계산(iteration)횟수가 증가할 수록 광역 최적값에 접근하는 결과를 보여주고 있다.

표 2. SQP와 유전알고리듬의 비교 결과.

Table 2. Comparisons of SQP and GAs.

SQP		유전알고리듬		
	반복횟수	목적함수값	반복횟수	목적함수값
Best	522	981.1	350	1723.5
Worst	132	4783.3	3000	392.8
Ave.	360.2	2714.7	60000	150.4

유전 알고리듬을 이용한 최적 제어는 두 가지 경우에 대해 시뮬레이션하였다. 첫 번째 방법은 전체 반응시간 동안 일정한 제어 입력 구간을 갖는 static range경우이고 두 번째 방법은 제어 입력값의 변화폭을 점차 줄여 주는 dynamic range경우이다. 그림 5의 결과에서 보듯이 dynamic range의 경우는 1,000번까지의 반복 계산만으로도 목적 함수값이 상당히 줄어드는 것을 볼 수 있으나 static range경우는 5,000번 이상의 반복 계산을 필요로 한다. 충분한 반복 계산횟수인 60,000번 이후에도 dynamic range의 목적함수값이 더 작다. 60,000번 반복 계산후의 최적화 결과에서 목적 함수값만을 비교하였을 때는 두 방법의 차이가 크지 않았으나 실제로 구한 분자량과 VA조성의 궤적을 비교해 보면 그림 6과 그림 7에서와 같이 dynamic range를 사용할 경우가 static range의 경우보다 원하는 물성치에 빠르게 도달하며 정상 상태가 상대적으로 잘 유지되는 것을

볼 수 있다. 그림 8과 그림 9는 최적 제어로 얻은 제어 입력 궤적으로 dynamic range의 경우는 반응 초기에는 변화가 크고 점차로 줄어들어 정상 상태를 보장해 주고 있으나 static range의 경우는 제어 입력값들의 변화 폭이 크며 정상 상태를 보장해 주지 못하고 있다.

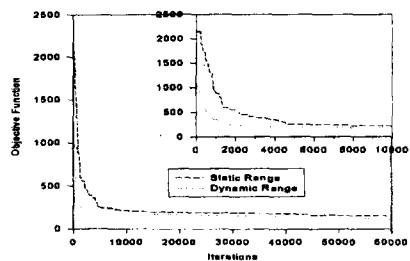


그림 5. 제어 목적 함수값의 변화.

Fig. 5. Control objective with iterations.

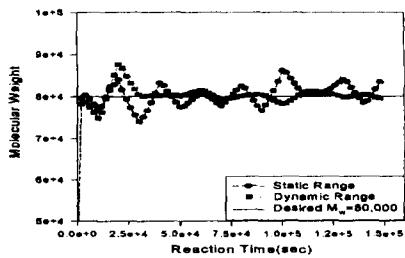


그림 6. 최적제어로 구한 분자량 궤적.

Fig. 6. Obtained molecular weight.

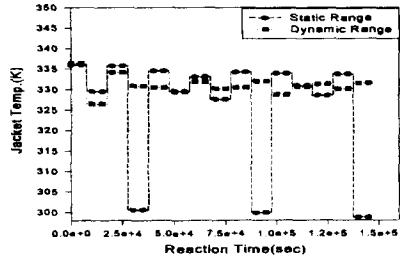


그림 7. 최적 제어로 구한 고분자내의 VA 조성.

Fig. 7. VA composition in copolymer.

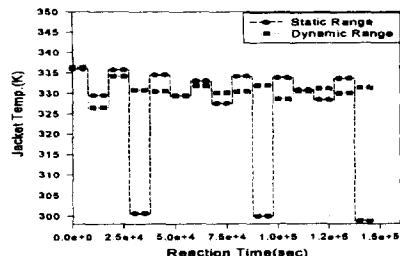


그림 8. Heat jacket온도의 최적 궤적.

Fig. 8. Optimal jacket temperature.

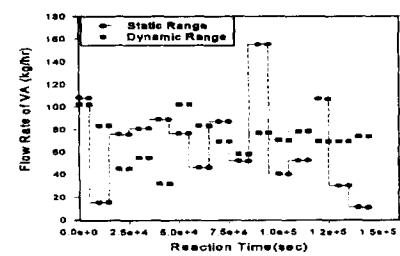


그림 9. VA의 최적 유량 궤적.

Fig. 9. Optimal flow rate of VA.

## V. 결론

연속 공정에서 최적 제어는 가능한 짧은 전환 시간 안에 공정을 원하는 물성을 갖는 정상 상태로 도달하게 하는 제어 입력 궤적을 구하는 것이다. 본 연구에서는 복잡하고 비선형성이 강한 연속 공정의 최적 제어를 위해 적용의 편이성과 강건성을 가진 유전 알고리듬과 정상 상태의 정보를 고려해 탐색 구간을 줄여주는 유동탐색구간을 이용한 방법을 제시하였다. 제시된 유동탐색구간을 갖는 유전알고리듬을 연속 MMA-VA공중합 고분자 반응기에 적용하여 SQP보다 광역의 최적값에 더 접근하는 결과를 얻었다. 또한 제시된 방법이 일정한 제어입력 구간을 갖는 유전알고리듬의 경우 보다 계산 시간과 정확도에서 우수하였다.

## 참고문헌

- [1] Ch. Kruse, G. Fieg and G. Wozny, "A new time-optimal strategy for column startup and product changeover," *J. Proc. Cont.*, vol. 6, pp. 119-127, 1996.
- [2] D. E. Goldberg, *Genetic Algorithms in Search, Optimization, and Machine Learning*, Addison-Wesley, 1989.
- [3] D. E. Kirk, *Optimal Control Theory*, Prentice-Hall, 1970.
- [4] H. M. Cartwright and R. A. Long, "Simultaneous optimization of chemical flowshop sequencing and topology using genetic algorithms," *Ind. Eng. Chem. Res.* vol. 32, pp. 2706-2713, 1993.
- [5] J. J. Grefenstette, "Optimization of control parameters for genetic algorithms," *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 16, pp. 122-128, 1986.
- [6] J. P. Congalidis, J. R. Richards and W. H. Ray, "Feed forward and feedback control of a solution copolymerization reactor," *AIChE J.* vol. 35, pp. 891-907, 1989.
- [7] J. -S. Chang and J. -L. Lai, "Computation of optimal temperature policy for molecular weight control in a batch polymerization reactor," *Ind. Eng. Chem. Res.*, vol. 31, pp. 861-868, 1992.
- [8] K. A. De Jong, *An Analysis of the Behavior of Genetic Adaptive Systems*, Dissertation, Michigan, 1975.
- [9] K. Krishnakumar, "Control system optimization using genetic algorithms," *J. Guidance, Control and Dynamics*, vol. 15, pp. 735-740, 1992.
- [10] S. -A. Chen and S. -T. Lee, "Minimum end time policies for batchwise radical chain polymerization," *Polymer Eng. and Sci.*, vol. 27, pp. 573-581, 1987.
- [11] Z. Michalewicz, C. Z. Janikow and J. B. Krawczyk, *A Modified Genetic Algorithm for Optimal Control Problems*, Computer Math. Applic., vol. 23, pp. 83-94, 1992.
- [12] 이무호, 연속 교반 반응기에서의 MMA-MA공중합 반응의 모델링 및 최적시간제어, 포항공과대학교, 석사논문, 1995.



이 무 호

1993, 1995년 포항공대에서 화학공학과 학사, 석사학위를 받았으며 1996년 현재 포항공대 화학공학과 박사 과정 진학중이며 지능자동화 연구센터 연구원으로 있다. 주요 관심 분야는 최적 제어와 공정 최적화, 공정 자동화, 실시간 공정 감시 및 진단 등이다.



한 종 훈

1984년, 1986년에 서울대학교에서 화학공학과 학사, 석사학위를 받았으며 1994년 MIT에서 박사학위를 하였다. 1987년~1988년 KIST연구원으로, 1993년 Molten Metal Technology 선임연구원, 1993년~1995년 MIT Post-doc 연구원으로 있었다. 1995년부터 포항공대 화학공학과 조교수로 있음. 주요 관심 분야는 공정 자동화, 지능 시스템, 실시간 조업 감시 및 진단 시스템 등이다.



장 근 수

1957년 한양대학교에서 화학공학과 학사학위후 1959년 미국 Argonne 국제 원자력학교를 수료하고 1959년~1963년 한국원자력연구소 연구관으로 근무하였으며 1964년 Northwestern 대학교에서 석사, 1967년 박사학위를 취득하고 캐나다 Waterloo 대학교에서 1966년~1969년 조교수, 1969년~1973년 부교수, 1973년~1989년 교수로 있었으며 1988년부터 포항공대 화학공학과 교수로 재직중이다. 1972년 이태리 CISM연구소에 초빙 교수, 1973년~1974, 1978년, 1981년, 1985년~1986년에 KIST, KAIST 초빙 교수를 지냈으며 1989년~1990년 산업과학기술연구소 부소장으로 재직하였고 1994년 한국화학공학회 회장을 역임하였다. 현재 과학재단지정 ERC 공정산업의 지능자동화 연구센터 소장. 연구분야는 공정 제어, 공정 최적화, 전산 제어, 공정 모델링, 공정 해석, 편미분 방정식 공정 시스템 제어 및 최적화 등이다.