

조선분야의 축적된 데이터 활용을 위한 유전적프로그래밍에서의 선형(Linear) 모델 개발

이경호^{† *}, 연윤석^{**}, 양영순^{***}

인하대학교 선박해양공학과*, 대진대학교 컴퓨터응용 기계설계공학과**
서울대학교 조선해양공학과***

Implementing Linear Models in Genetic Programming to Utilize
Accumulated Data in Shipbuilding

Kyung-Ho Lee^{† *}, Yun-Seog Yeun^{**} and Young-Soon Yang^{***}

Dept. of Naval Architecture and Ocean Engineering, INHA University^{*}
Dept. of Mechanical Design Engineering, DaeJin University^{**}
Dept. of Naval Architecture and Ocean Engineering, Seoul National University^{***}

Abstract

Until now, Korean shipyards have accumulated a great amount of data. But they do not have appropriate tools to utilize the data in practical works. Engineering data contains experts' experience and know-how in its own. It is very useful to extract knowledge or information from the accumulated existing data by using data mining technique. This paper treats an evolutionary computation based on genetic programming (GP), which can be one of the components to realize data mining. The paper deals with linear models of GP for the regression or approximation problem when given learning samples are not sufficient. The linear model, which is a function of unknown parameters, is built through extracting all possible base functions from the standard GP tree by utilizing the symbolic processing algorithm. In addition to a standard linear model consisting of mathematic functions, one variant form of a linear model, which can be built using low order Taylor series and can be converted into the standard form of a polynomial, is considered in this paper. The suggested model can be utilized as a designing tool to predict design parameters with small accumulated data.

※Keywords: Genetic programming(유전적프로그래밍), Datamining(데이터마이닝), Data analysis & prediction(데이터 해석 및 성능예측), Linear model(선형 모델)

접수일: 2004년 11월 5일, 승인일: 2005년 7월 13일

†주저자, E-mail : kyungho@inha.ac.kr

Tel : 032-860-7343

1. 서론

최근 들어, 조선분야뿐만 아니라 산업 전 분야에서 지식의 중요성이 부각되고 있다. 기업이 어떤 지식을 보유하고 있으며, 이 지식이 어떻게 조직 내에서 공유되며 활용을 극대화 할 수 있느냐가 기업의 경쟁력이 되고 있다. 이를 위하여 지식 관리도 이야기하고 있으며, 전사적인 ERP(Enterprise Resource Planning) 구축에 총력을 다하고 있다. 그러나 이것이 성공하기 위해서는 무엇보다도 축적된 공학 데이터의 활용 측면을 간과해서는 안 된다. 전문가의 경험이나 노하우로부터 만들어진 축적된 데이터로부터 유용한 정보나 지식을 얻고자 하는 연구분야가 데이터마이닝(Data Mining)이며, 데이터마이닝의 구성요소 중에서 데이터의 분석(Analysis) 및 이를 통한 성능 예측(Prediction)을 위한 학습 시스템의 구축은 반드시 선행되어야 할 문제라고 할 수 있다.

조선 1 등국인 우리나라의 조선 현장에서는 그동안의 축적된 많은 양의 데이터를 가지고 있지만 이를 데이터를 활용하기 위한 도구를 보유하고 있지 못한 것이 현실이다. 따라서 데이터의 적극적인 활용 방법론을 확보하는 것이 어느 때보다 필요한 시기이다.

본 논문은 축적된 데이터의 활용을 위한 데이터 분석 및 성능예측 방법론을 개발하는 것이다. 여기에서는 유전적 프로그래밍(Genetic Programming: 이하 GP 라함) 기법을 도입한 방법론을 다루고 있는데, GP 는 통계학에서의 Regression 방법과 같은 결정론적 방법이 아니라 함수, 즉 트리의 구조가 적합도를 최적화하기 위해 동적으로 변함으로써 새로운 경험식을 생성할 수 있다. 특히 본 논문에서는 이러한 특징을 가진 GP 를 활용하여 축적된 데이터의 수가 학습(Learning)을 수행하기에 부족할 경우 사용할 수 있는 방법론을 제시하기 위한 것이다. 이경호와 연윤석(2004)에서는 이미 유전적프로그래밍 기법이 데이터의 비선형 영역에서 탁월한 학습능력을 가지고 있으며, GP 트리의 함수집합으로 수학함수 대신 간단하고 다루기 쉬운 다항식(Polynomial)을 도입함으로써 학습성능을 향상시킬 수 있음을 제시하였다. 그러나 여기

에서는 트리 구조를 사용하고, 좋은 트리 구조를 찾기 위한 적합도 함수에 대한 비선형 최적화 과정을 거침으로써 많은 계산시간이 필요하게 된다.

본 논문은 근사 모델이 간단하면서도 학습 시스템의 일반화 성능을 향상시킬 수 있는 선형 모델(Linear Model)을 개발하는 것이 목적이라 할 수 있다. 이를 위하여 MDL(Minimum Description Length) 방법(Hansen & Bin 2001)과 적은 양의 학습 데이터로부터 학습 시스템의 일반화 성능을 높이기 위하여 DDBS(Directional Derivative Based Smoothing)을 도입하였다. 이를 통해 비선형성이 강하고 학습 데이터의 수가 비교적 적은 영역에서 학습성능이 우수한 근사 모델을 찾기 위한 선형 모델에 의한 방법론을 제시하였으며, 이를 선박설계에 적용한 예를 통해 그 효용성을 검증하였다.

2. 유전적 프로그래밍 개요

GP 는 유전적 알고리즘(GA)의 확장으로써 그 개체(Individual)가 트리(Tree) 형태의 컴퓨터 프로그램이 된다(이경호등 1998). 여기서의 컴퓨터 프로그램은 터미널 집합(Terminal set)과 함수 집합(Function set)의 조합으로 생성된 문법적으로 올바른 GP 트리를 뜻한다. 진화과정을 통하여 GP 트리는 적합도(Fitness)를 최적화하기 위해서 그 구조 자체가 동적으로 변화하는데, 적합도 계산을 위해서 트리의 학습오차(Learning error)를 계산할 수 있는 함수가 사용된다. 기저함수 바탕의 근사화 기법은 그 함수의 형태가 이미 결정되어 있는 반면, GP 에서는 함수 즉 GP 트리의 구조 자체가 적합도를 최적화하기 위하여 변화된다. 이러한 특징을 고려할 때, GP 는 함수 근사화 및 데이터마이닝의 유용한 도구로 활용될 가능성이 크다(이경호와 연윤석 2004). 그러나 GP 의 가장 큰 단점 중의 하나가 진화의 과정을 통하여 학습을 하는 과정에서 많은 양의 데이터와 복잡한 트리 구조를 최적화해 나감으로 인해 계산시간이 많이 소요된다는 것이다. 또한 대부분의 공학 문제에서 GP 의 학습에 이용할 만큼의 일관성 있는 많은 양의 실제 데이터를 얻는다는 것도 쉽지는 않다. 이러한

문제를 해결하기 위한 방법으로 GP의 복잡한 트리 구조 대신 선형 모델을 도입하고, 이를 통해 학습 오류가 적으면서 간단한 근사 모델로서 좋은 일반화 성능을 보이는 모델을 찾음으로써 계산시간을 줄이고 적은 양의 학습 데이터를 가지더라도 우수한 성능을 나타내는 함수 근사 방법론을 제시하고자 한다.

3. 유전적 프로그래밍에서의 선형모델 구현

일반적으로 회귀분석이나 함수근사의 문제는 주어진 샘플 데이터를 바탕으로 일반적 성능을 가진 우수한 모델을 찾는 것이다. 이를 위해서 가장 중요한 문제는 생성할 모델에 사용될 적절한 기저 함수의 형식을 선택하는 것이다. 기저함수가 선택되면 이들의 조합을 통해서 적절한 모델을 생성해 간다. 여기에서는 근사 모델의 구조가 고정되어 있다. 이와는 달리 GP를 이용하게 되면 GP 트리의 구조 자체가 점진적 진화연산에 의해 개선되고 최적화되어 더 적절하고 정교한 근사모델을 얻을 수 있는 확률을 높일 수 있다. 이러한 이유로 GP는 회귀분석이나 시스템 인식(System Identification) 분야에서 활발하게 적용되고 있다 (Gray et al. 1996).

3.1 MDL에 의한 최적 선형모델 생성

GP가 유전적 진화연산에 의해 생성되는 트리 구조를 사용함으로써 매우 잠재능력을 가진 도구로서 평가되지만 또한 이것이 GP의 큰 단점이 될 수도 있다. 예를 들어,

$\theta_1(+ \theta_2x_1 \theta_3(* \theta_4x_2 \theta_5(\sin \theta_6(+ \theta_7x_3 \theta_8x_4))))$

와 같은 트리를 생각하면, 여기서 θ_i 는 각 노드에 붙어진 가중치(Weight)이고 x_i 는 변수(Variable) 또는 상수(Constant)임. 이 트리는 비선형 함수로서 θ_i 를 구하기 위해서는 복잡하고 많은 양의 계산을 요하는 비선형 최적화 방법을 사용해야 한다.

일반적으로 좋은 모델을 생성하는 데는 모델의 일반화 성능이 우수해야 한다. 또한 이것은 모델의 복잡도와 연관되어 있다. 보통 모델이 복잡하면 학습 성능은 뛰어나지만(학습 오차가 적음) 테

스트 오차가 매우 크게 되는 Overfitting 경향을 나타낸다. 이러한 현상은 학습 데이터의 수가 적을 때 발생하기 쉽다. 이러한 문제를 해결하기 위한 방법으로 본 논문에서는 일반적인 GP 트리 구조로부터 Symbolic Processing 알고리즘을 활용하여 선형 모델을 생성하였으며, 가장 성능이 뛰어난 모델을 선정하기 위하여 GP의 적합도 함수로서 MDL 방법을 도입하였다. 여기서, MDL은 Ockham's Razor(Barron et al. 1998)와 밀접하게 관련되어 있는데, 즉 학습 데이터를 잘 근사하면서 가장 단순한 모델이 가장 좋은 일반화 성능을 나타내는 모델이라는 것이다.

일반적인 선형 모델은 식 (1)과 같이 표현된다.

$$y = \sum_i \theta_i x_i = \underline{\theta} \underline{x}^T \quad (1)$$

여기서, $\underline{\theta}$ 는 구하고자 하는 파라미터 θ_i 의 벡터이고, \underline{x} 는 d 차원의 설계변수이다. y 는 θ_i 의 선형 함수로서 선형 모델이라 한다. 식 (1)은 식 (2)와 같이 확장될 수 있다.

$$y = \sum_{i=1}^{k-1} \theta_i b_i = \underline{\theta} \underline{b}^T \quad (2)$$

여기서, $k-1$ 은 기저함수(Base Function)의 수이고, $\underline{b} = (b_i)_{i=1}^{k-1}$ 는 d 차원 벡터 \underline{x} 로부터 선택된 변수들의 임의의 연속 함수의 벡터이다. 식 (2)도 여전히 선형 모델이고, b_i 는 표준 기저함수가 아니며, b_i 와 b_j ($i \neq j$)는 같은 함수 형태가 아니다. 만일 학습 데이터 세트가 $L = \{(z_i, t_i)\}_{i=1}^n$ 이라고 할 때, 여기서 z_i 는 d 차원 벡터 (z_1^i, \dots, z_d^i) 이고, t_i 는 목표치(Target Value)임. GP의 임무는 L 에 담겨진 정보로부터 \underline{b} 를 찾아내는 것이다.

간단한 예를 들어 설명하면 다음과 같다.

전형적인 GP 트리로부터 선형 모델을 만들기 위해서는 먼저 식 (2)에서의 기저함수 b_i 를 먼저 추출해야 한다. 만일 다음과 같이 생성된 GP 트리 하나를 생각해보자.

$$(- (* 0.7 (* 1.5 (\sin (+ x_1 (* 0.3 (\exp x_2)))))))$$

$$(* (* 0.1 (* x_1 x_3)) (* x_1 (\cos (-x_2 1)))))$$

Table 1 Mathematic functions used for GP functions

cos, acos, sec, asec, sin, asin, csc, acsc, tan, atan, cot, acot, cosh, acosh, sech, asech, sinh, asinh, csch, tanh, atanh, coth, acoth, sqrt, exp, log(ln), iexp(1/exp)

Table 2 Taylor series used for GP functions

Symbol	Math. function	Taylor series	Symbol	Math. function	Taylor series
tcos	$\cos(x)$	$1 - 1/2x^2$	tsqrt	$(1+x)^{1/2}$	$1 + 1/2x - 1/8x^2 + 1/16x^3$
tsec	$\sec(x)$	$1 + 1/2x^2$	tsqrt	$(1+x)^{-1/2}$	$1 - 1/2x + 3/8x^2 - 5/16x^3$
tsin	$\sin(x)$	$x - 1/6x^3$	texp	$\exp(x)$	$1 + x + 1/2x^2 + 1/6x^3$
ttan	$\tan(x)$	$x + 1/3x^3$	tlog	$\log(1+x)$	$x - 1/2x^2 + 1/3x^3$
tcosh	$\cosh(x)$	$1 + 1/2x^2$	tpx	$(1+x)^{-1}$	$1 - x + x^2 - x^3$
tsinh	$\sinh(x)$	$x + 1/6x^3$	t2px	$(1+x)^{-2}$	$1 - 2x + 3x^2 - 4x^3$
ttanh	$\tanh(x)$	$x - 1/3x^3$	texpsin	$\exp(\sin(x))$	$1 + x + 1/2x^2$
tlogcos	$\log(\cos(x))$	$-1/2x^2$	texpant	$\exp(\tan(x))$	$1 + x + 1/2x^2 + 1/2x^3$

이렇게 GP에서 생성된 트리 구조를 표준 수학
함수 형태로 고쳐보면 다음과 같다.

$$1.05 \sin(x_1 + 0.3 \exp(x_2)) + (-0.1)x_1^2 x_3 \cos(x_2 - 1)$$

이 식으로부터 우리는 다음과 같은 3 개의 기저함수를 찾아낼 수 있다.

$$\begin{aligned} b_1 &= 1, \quad b_2 = \sin(x_1 + 0.3 \exp(x_2)), \\ b_3 &= x_1^2 x_3 \cos(x_2 - 1) \end{aligned}$$

그러면 θ_i 는 OLS (Ordinary Least Square Method)에 의해 쉽게 구해진다. 이러한 변환은 궁극적으로 GP 트리로부터 가능한 모든 기저함수를 모으기 위한 것이다.

GP에서 사용되는 터미널 노드와 함수 세트는 다음과 같다.

$$T_{GP} = \{x_1, \dots, x_d, R, \text{one}\}$$

$$F_{GP} = \{g_1, g_2, \dots, +, -, *\}$$

여기서, R 은 $|R| < 1$ 인 난수(Random Number)이고, ‘one’은 1이며, g_i 는 임의의 연속 함수이다.

g_i 로서 본 논문에서는 Table 1과 같은 다양한 수학 함수를 사용하고 있다. 또한 g_i 로서 수학함수 대신 Table 2에 정의한 함수에 해당하는 Low order Taylor Series를 사용하게 되면 이경호 (2004)에서 사용한 다항식 기반의 GP가 된다. 본




Fig. 1 Generation of Virtual Data by DDBS

논문에서는 이러한 다항식을 이용한 GP 트리로부터의 선형모델 생성(이를 LM-GP라 함)을 다루고 있는데, 이것을 특별히 PLM-GP (LM-GP with Polynomial)이라 한다.

3.2 DDBS에 의한 가상 데이터 생성

일반적으로 MDL에 의한 선형모델 생성은 계산양을 줄여준다는 장점을 가지고 있지만 일반적으로 데이터의 양이 많은 때 좋은 결과를 보여준다.

본 논문에서와 같이 데이터의 수가 제한되어 있는 경우에 대해서는 좋은 모델을 만들어 준다는 보장을 할 수가 없게 된다. 더구나 이렇게 데이터의 수가 적고, 선형 모델의 기저함수 자체가 진화연산 과정에서 비선형성을 보일 때, 이렇게 생성된 모델은 과도한 Overfitting 경향을 보이게 된다. 이러한 문제를 해결하기 위하여 MDL과 병행하여 방향성을 가지고 가상 데이터를 생성 시킬 수 있는 DDBS (Directional Derivative based Smoothing) 방법의 도입이 요구된다.


Fig.1에서와 같이 선형 모델 y 가 주어지면, y 의 거동은 가장 인접한 두 샘플 포인트인 z_i 과 z_j 로부터 이 두 점을 연결하는 i,j,l 선을 따라 탐색을 하면서 원치 않는 급격한 Peak나 Valley가 발생한 곳에서 y 의 방향 도함수를 사용하여

새로운 점들을 찾게 된다.


DOBS를 사용하면 y 의 부드러운 결과를 효과적으로 얻을 수 있을 뿐만 아니라 샘플 데이터의 추가 없이도 효과적인 학습을 수행할 수 있게 된다.

4. 검증 예


본 논문에서 개발된 GP의 선형모델을 검증하기 위해 수학적 함수의 근사를 수행하였다. 이것은 일반적인 표준 GP가 학습 데이터의 수가 적을 경우 비정상적인 현상을 나타낼 수 있으며, LM-GP 또는 PLM-GP의 도입을 통해 이 문제를 해결 할 수 있음을 보이기 위한 것이다.




a. The original function.



b. Generated lines for creating virtual samples.



c. The best result of LM-GP.



d. The best result of PLM-GP.

Fig.2 Fitting results of the Rosen Brock's function with noiseless samples.

$$\begin{aligned}
 & 0.995 - 1.404x_2 - 2.859x_1 + 6.883E-1x_2^2 + 3.217x_1x_2 - 1.407E1x_1^2 - 4.718E-1x_1x_2^2 - 1.667E-1x_2^3 + 1.182E2x_1^3 - \\
 & 1.481x_1^2x_2 + 6.665E-3x_1x_2^3 - 7.959E-1x_1^3x_2 - 1.957E-1x_1^2x_2^2 - 4.123E2x_1^4 + 2.651E-1x_1x_2^4 - 9.611E-1x_1^4x_2 + \\
 & 9.560E2x_1^5 + 7.688E-1x_1^2x_2^3 - 2.171x_1^3x_2^2 - 1.663E3x_1^6 - 1.050x_1^4x_2^2 - 2.941x_1^5x_2 - 1.750Ee1x_1^2x_2^4. \\
 & \dots \\
 & -1.017E-1x_1^7x_2^7 - 1.533E1x_1^14 + 1.186E-1x_1^12x_2^2 - 2.209E-1x_1^8x_2^7 + 6.746E-2x_1^11x_2^4 - 2.791E-1x_1^10x_2^5 - \\
 & 3.374E-2x_1^12x_2^3 - 5.438E-1x_1^9x_2^6 + 3.389E-2x_1^9x_2^7 + 2.283E-1x_1^10x_2^6 - 3.858E-2x_1^12x_2^4 - 7.216E- \\
 & 2x_1^11x_2^5 + 3.624E-2x_1^12x_2^5 + 2.455E-2x_1^10x_2^7 + 6.042E-2x_1^11x_2^6 - 3.008E-2x_1^12x_2^6 - 3.765E-3x_1^11x_2^7
 \end{aligned}$$

Fig.3 The polynomial transformed from the best linear model of PLM-GP

검증을 위해 사용한 함수는 Rosen Brock 함수 (Rosenbrock 1960)이며, 단지 6x6 개의 학습 데이터와 25x25 개의 테스트 데이터를 그리드로 생성하여 사용하였다.

Rosen Brock 함수는 다음과 같으며, GP에 사용된 파라메터 값들은 Table 3과 같다.

$$\begin{aligned}
 y &= 100(x_2 - x_1^2)^2 + (1 - x_1)^2 \\
 -2 \leq x_i &\leq 2, i = 1, 2
 \end{aligned}$$

또한 Fig.2는 그 결과이다. 예상대로 적은 수의 데이터에서도 LM-GP와 PLM-GP는 우수한 학습 성능을 나타내고 있음을 알 수 있다. Fig.3은 PLM-GP의 선형 모델로부터 변환된 다항식의 결과이다.

Table 3 The default parameters used for GP

Population size	300
Max. generation	100
Selection method	Tournament with 20 trees
Reproduction probability	0.15
Crossover probability	0.7
Mutation probability	0.15

5. 선박설계 적용 예

개발된 시스템의 실세계 적용을 위하여 산적화 물선(Bulk Carrier)의 주요치수 추정 문제를 다루었다. 현실적으로 실적 데이터의 수집이 어렵고, 데이터 자체도 일부 일관성이 결여되어 있지만 학습 경향은 파악할 수 있다.

여기서는 선주의 요구조건(DWT, Vs)에 따라 주요치수별 학습을 수행하였다. 학습 데이터로는 80

Table 4 The estimation of the principal dimensions of bulk carriers.

L_{BP}	Learning error	LM-GP	5.36341
		PLM-GP	5.66651
		NN	5.16004
		MARS	5.21958
B	Test error	LM-GP	5.24520
		PLM-GP	5.15973
		NN	6.09057
		MARS	5.66843
D	Learning error	LM-GP	0.96482
		PLM-GP	0.78226
		NN	1.09823
		MARS	1.16696
	Test error	LM-GP	0.91381
		PLM-GP	0.91681
		NN	1.21973
		MARS	1.16952

개의 실적 데이터를 사용하였으며, 일부 노이지를 포함하고 있다. Fig. 4는 주요치수 중 선박의 길이 (LBP) 추정의 결과만을 실었다.

Table 4에서는 주요치수 LBP, B, D에 대한 추정 결과를 타 학습 시스템과 비교를 수행한 것이다. PLM-GP의 경우 타 시스템보다 성능이 우수하였고, 본 학습에서 사용한 실적 데이터 자체가 자체의 노이지를 가지고 있고 그런 데이터를 학습의 검증을 위한 테스트 데이터로 사용함으로써 약


간의 차이를 보이고 있다. 그러나 Fig. 4 에서 볼 수 있듯이 LM-GP 나 PLM-GP 에 의해 Fitting 된 함수는 나름대로 만족할 만한 결과라고 판단된다.

6. 결론


본 논문은 조선 현장의 축적된 데이터를 효율적으로 활용할 수 있도록 데이터 분석 및 성능 예측을 위한 조선분야에 적합한 도구를 개발하는데 그 목적이 있다. 지금까지 공학 데이터의 축적을 위한 도구에 대한 노력과 연구는 많이 되어왔다. 그러나 이것의 활용 측면에서는 많은 연구가 없었던 것이 사실이다. 본 연구를 통하여 축적된 데이터

활용을 위한 유전적프로그래밍 방법의 접근에 대해 소개하였으며, 특히 유전적프로그래밍 방법의 진화적 성능 향상을 도모하면서 간단하고 효율적인 선형(Linear) 모델의 개발을 통해 데이터의 일반화된 학습 성능을 높이고, 학습 데이터의 수가 적은 경우에도 뛰어난 학습 성능을 발휘하는 시스템을 개발하였다.


이러한 방법론은 조선 현장의 데이터를 효과적으로 활용할 수 있는 도구로 사용될 것으로 기대하며, 궁극적으로는 데이터로부터 유용한 정보 및 지식을 추출해 내는 데이터마이닝의 도구로 사용될 것이다.




a. The learning results of LM-GP.



b. The learning results of PLM-GP.



c. The test results of LM-GP.



d. The test results of PLM-GP.

Fig. 4 The results of two linear models for estimating L_{BP}

후기

이 논문은 2004년도 한국학술진흥재단의 지원에 의해 연구되었음 (KRF-2004-041-D00817)

참고문헌

- 이경호, 연윤석, 양영순, 1998, “개선된 유전적 프로그래밍 기법을 이용한 설계 파라메터 추정,” 대한조선학회 설계연구회 하계발표회.
- 이경호, 연윤석, 2004, “데이터마이닝을 위한 다행식기반의 유전적프로그래밍 기법과 조선분야 응용,” 대한조선학회 춘계학술대회 논문집. pp. 845–850
- Barron A., Rissanen J. and Yu B., 1998, “The Minimum Description Length Principle in Coding and Modeling,” IEEE Trans. Information Theory, Vol. 44, No. 6, pp. 2743–2760.

• Gray G.J., Murray D.J. and Sharman K.C., 1996, “Structural System Identification using Genetic Programming and a Block Diagram oriented Simulation Tool,” Electronics Letters, Vol. 32, pp. 1422–1424.

• Hansen, M.H. and Bin, Y., 2001, “Model selection and the principle of minimum description length,” J. of American Statistical Association, Vol. 96, No. 454, pp. 746–774.

• Rosenbrock, H.H., 1960, “An automatic method for finding the greatest or least value of a function,” Computer Journal, Vol. 3, pp. 175–184.



<이경호>



<연윤석>



<양영순>