

## $r$ -fold Wiener process에 대한 유한근사함수의 특성에 관한 연구

최성희\*, 황석형\*\*

### A study on the properties of the finite-dimensional approximation of an $r$ -fold Wiener Process

Sung-Hee Choi\*, Suk-Hyung Hwang\*\*

#### 요 약

$r$ -fold Wiener process는 실질적으로 infinite dimension이고, 컴퓨터는 finitely dimensional subspace 만 취급할 수 있기 때문에  $r$ -fold Wiener process는 컴퓨터로 구현될 수 없다. 따라서 본 논문에서는  $r$ -fold Wiener process의  $m$ -dimensional approximation 함수의 특성에 대해 연구한다.

▶ Keywords : Wiener process, average case 오차, Probability measure

#### Abstract

Because the  $r$ -fold Wiener process is truly infinitely dimensional and a computer can only handle finitely dimensional subspaces, we study in this paper the basic properties of the  $m$ -dimensional approximation function of the  $r$ -fold Wiener process.

▶ Keywords : Wiener process, average case error, Probability measure

---

• 제1저자 : 최성희

• 투고일 : 2012. 12. 27, 심사일 : 2013. 1. 29, 게재확정일 : 2013. 2. 23.

\* 제1저자, 선문대학교 컴퓨터공학과

\*\* 선문대학교 컴퓨터공학과

## I. 서론

Information-based complexity를 연구하는 분야에서 다루는 문제 중에서는 complexity를 분석하기가 아주 어렵거나, 아예 불가능한 문제들이 있다. 예를 들어  $n$ 개의 데이터를 사용하는 수치적분문제에서 minimal 오차가  $\Theta(n^{-p})$ 인 것이 알려져 있는데 여기서 비록 정수  $p$ 값을 알고 있다하더라도  $\Theta$ -notation에서 사용되는 상수의 값을 우리는 알지 못한다. 따라서 프로그래밍할 때 언제 계산을 끝내야할지 모르기 때문에 optimal 알고리즘을 프로그래밍하는데에는 어려움이 있다. 또 다른 예로 어떤 함수  $f \in C^r$  (여기서  $r$ 은 0이상의 정수이며 집합  $C^r$ 은  $r$ 차 도함수가 연속인 함수의 집합을 말한다)의 global maximum의 근사값을 찾는 문제인 global optimization 문제에서는 어떤 정수  $r$ 이  $r \geq 1$ 일 때  $\max_x f(x)$ 의 분포(distribution)가 알려져 있지 않아서 가장 간단한 알고리즘에서조차 그 average case 오차를 알 수가 없다. 이러한 문제들을 다룰 때, 만약 우리가  $r$ -fold Wiener measure  $\omega_r$ 에 의해 분포되는 random 함수들을 만들어낼 수 있다면 random method를 사용하여 위 문제들에 대해 complexity를 보다 쉽게 계산할 수 있을 것이다. 따라서 본 논문에서는  $r$ -fold Wiener random 함수의 특성 ([2], [5] 참조)에 대해 연구한다.

Information-based complexity 분야에서 계산하는 average case 오차는  $L_2$ -norm을 사용하여 측정되는 function approximation 문제에서, 어떤 양수  $r$ 에 대해서  $r$ -fold Wiener measure  $\omega_r$ 과 양수  $m$  (여기서  $m$ 은 주어진 information의 개수를 나타냄)과 information

$$M_m(f) = [L_1(f), L_2(f), \dots, L_m(f)]$$

( $L_i$  : some linear functional)

이 주어지면, algorithm  $\phi$ 를 사용하여 이 문제를 푸는 경우 average case 오차

$$e^a(\phi, M_m, L_2; \omega_r) = \sqrt{E_{\omega_r}(\|f - \phi(M_m(f))\|_2^2)}$$

는  $\omega_r(\cdot | M_m(f) = y)$ 의 conditional mean인 algorithm  $\phi(y) = \psi_m^*(y)$ 에 의해서 최소화된다. 따라

서 average case 오차는 일차적으로는 문제에 주어지는 information  $M_m$ 에 따라 변화하고, 이차적으로는 사용하는 알고리즘  $\phi$ 에 따라 그 값이 변화한다. 본 논문에서는 같은 알고리즘을 사용한다고 가정할 때, average case 오차를 최소화하는 몇 가지의 information에 대한 특성에 대해 연구한다.

## II. 용어정의

본 논문에서는 함수의 집합에 probability measure인  $r$ -fold Wiener measure  $\omega_r$ 이 주어진다고 가정한다. 여기서  $\omega_r$ 은 평균이 0이고 correlation function이

$$E_{\omega_r}(f(x)f(y)) = \int_F f(x)f(y)\omega_r(df)$$

$$= \int_0^1 \frac{(x-t)_+^r}{r!} \frac{(y-t)_+^r}{r!} dt$$

인 Gaussian measure이다. 여기서

$$(z-t)_+ = \max(0, z-t)$$

를 의미한다. 다시 말해서  $\omega_r$ 에 의해 분포되는 함수  $f$ 는 평균이 0이고 autocorrelation이 위와 같이 주어진 Gaussian stochastic process이다. 또한  $\omega_r$ 에 의해 분포되어 있기 때문에 boundary condition 인

$$f(0) = f'(0) = f''(0) = \dots = f^{(r)}(0) = 0$$

을 만족한다.

$r$ -fold Wiener process는 사실상 infinite dimension 이고 컴퓨터에서는 finitely dimensional subspaces만 취급할 수 있기 때문에 진짜  $r$ -fold Wiener process  $f$ 는 컴퓨터로 구현될 수 없다. 따라서 process  $f$ 의 근사함수에 대하여

$$\dim(\text{lin } f_m) = m, f_m \rightarrow f \text{ as } m \rightarrow \infty$$

를 만족하는 approximate random process  $f_m$ 의 성질을 본 논문에서 연구한다.

### III. r-fold Wiener Process의 유한근사함수

오차가  $L_2$ -norm을 사용하여 측정되는 function approximation 문제에서, 어떤 양수  $r$ 에 대해서  $r$ -fold Wiener measure  $\omega_r$ 과 양수  $m$  (여기서  $m$ 은 주어진 information의 개수를 나타냄)과 information

$$M_m(f) = [L_1(f), L_2(f), \dots, L_m(f)]$$

( $L_i$  : some linear functional)

이 주어지면, algorithm  $\phi$ 를 사용하여 이 문제를 푸는 경우 average case 오차

$$e^a(\phi, M_m, L_2; \omega_r) = \sqrt{E_{\omega_r}(\|f - \phi(M_m(f))\|_2^2)}$$

는  $\omega_r(\cdot | M_m(f) = y)$ 의 conditional mean 인 algorithm  $\phi(y) = \psi_m^*(y)$ 에 의해서 최소화된다. 이러한 최소 오차는 information  $M_m$ 의 radius라 불리며  $e^a(M_m, L_2; \omega_r)$ 로 표기된다. 따라서 어떤 함수  $g_i \in L_2$ 에 대해서,

$$\psi_m^*(y)(x) = \sum_{i=1}^m y_i \cdot g_i(x)$$

이다. 사실상  $\psi_m^*$ 는 다른 어떠한 norm을 사용한다 하더라도 function approximation 문제에서의 average case 오차를 최소화시킨다. 특히, 임의의  $q > 0$ 와  $p = \infty$ 를 포함하는 임의의  $p > 1$ 에 대해서

$$E_{\omega_r}(\|f - \psi_m^*(M_m(f))\|_p^q) = \min_{\phi} E_{\omega_r}(\|f - \phi(M_m(f))\|_p^q).$$

또한 임의의 linear operator  $S$ 에 대해서  $S(\psi_m^*(M_m(f)))$ 는  $S(f)$ 를 approximating 하는 문제의 average case 오차를 최소화시킨다. 즉,

$$e^a(M_m, S; \omega_r) = e^a(S \circ \psi_m^*, M_m; \omega_r) = \min_{\phi} \sqrt{E_{\omega_r}(\|S(f) - \phi(M_m(f))\|^2)}.$$

여기서 random function  $f_m$ 의 기본적인 성질에 대해 알아본다. 주어진 문제에 대한 average case 오차는 일차적으로는 information  $M_m$ 에 따라 변화하고, 이차적으로는 사용하는 algorithm  $\phi$ 에 따라 그 값이 변한다.

**Theorem1.** 어떤 algorithm  $\phi$ 에 대해서 average case 오차를 최소화시키는 information은

$$M_m^*(f) = \left[ \frac{\langle f, \eta_1 \rangle_2}{\sqrt{\lambda_1}}, \dots, \frac{\langle f, \eta_m \rangle_2}{\sqrt{\lambda_m}} \right]$$

이며 이때의 오차는

$$\sqrt{E_{\omega_r}(\|f - \phi(M_m^*(f))\|_2^2)} = \Theta\left(\left(\frac{1}{m}\right)^{r+\frac{1}{2}}\right)$$

이다. 여기서  $\lambda_i$ 와  $\eta_i$ 는  $T_r$ 의 eigenpairs이며

$$T_r \eta_i = \lambda_i \eta_i, \lambda_1 \geq \lambda_2 \geq \dots, \langle \eta_i, \eta_j \rangle_2 = \delta_{ij}$$

를 만족한다.  $\langle \cdot, \cdot \rangle_2$ 는  $L_2$  inner product를 나타내며  $T_r$ 는 integral operator

$$(T_r f)(x) = \int_0^1 K_r(x, t) f(t) dt$$

로써  $K_r(x, t)$ 는  $\omega_r$ 의 covariance function이다.

**Proof:** 증명은 [5]를 참조하기 바란다. ■

**Theorem2.**  $m$ 개의 등간격점(equally spaced points)에서의 함수값으로 구성된 information

$$M_m^{st}(f) = \left[ f\left(\frac{1}{m}\right), \dots, f\left(\frac{m}{m}\right) \right].$$

을 사용할 경우 average case 오차는

$$\sqrt{E_{\omega_r}(\|f - \psi_m^*(M_m^{st}(f))\|_2^2)} = \Theta\left(\left(\frac{1}{m}\right)^{r+\frac{1}{2}}\right)$$

이 된다.

**Proof:** 이 information에 대응되는 optimal algorithm  $\psi_m^*$  는  $m$  개의 등간격점을 사용하여 함수  $f$  를 보간하는  $2r+1$  차의 natural spline 함수에 의해서 주어진다. 이 증명 또한 [5]를 참조하기 바란다. ■

따라서 Theorem1과 Theorem2에 의해  $M_m^{st}$  도  $M_m^*$  만 큼 오차를 최소화시키는 information이 된다. 본 논문에서 사용할 또 다른 information  $M_m^r$  은 등간격점에서의 함수  $f^{(r)}$  의 함수 값으로 구성된다.

$$M_m^r(f) = \left[ f^{(r)}\left(\frac{1}{m}\right), \dots, f^{(r)}\left(\frac{m}{m}\right) \right].$$

**Theorem3.** Information  $M_m^r(f)$  을 사용하여  $e^a(M_m^r, L_2; \omega_r)$  과  $e^a(M_m^r, \int; \omega_r)$  을  $L_2$  -approximation 문제와 적분문제에서의 average radius라 고 하자. 그러면  $r \geq 1$  일 때

$$e^a(M_m^r, L_2; \omega_r) = \Theta\left(\frac{1}{m}\right) = e^a(M_m^r, \int; \omega_r).$$

**Proof:** 상한은 [3]과 이미 알려져 있는 사실  $e^a(M_m^0, \int; \omega_r) = \Theta(1/m)$  에 의해

$$e^a(M_m^r, \int; \omega_r) \leq e^a(M_m^r, L_2; \omega_r) \leq e^a(M_m^0, \int; \omega_r)$$

이다. 따라서 본 증명에서는 적분문제에서의 하한만 증명 하면 된다.

$g$  를  $\omega_r$  에 의해 분포되어 있고,  $f$  를  $w_0$  에 의해 분포되어 있다고 하자.  $\omega_r = \omega_0 \circ D^r$  이므로  $f(x) = g^{(r)}(x)$  이다.

증

$$g(x) = \int_0^1 \frac{(x-t)_+^{r-1}}{(r-1)!} f(t) dt.$$

따라서 적분문제에서의  $M_m^r$  의 average radius는

$$\begin{aligned} & (e^a(M_m^r, \int; \omega_r))^2 \\ &= E_{\omega_r} \left[ \left( \int_0^1 g(x) dx - \psi_r^*(M_m^r(g)) \right)^2 \right] \\ &= E_{\omega_0} \left[ \left( \int_0^1 \int_0^1 \frac{(x-t)_+^r}{(r-1)!} f(t) dt dx - \psi_0^*(M_m^0(f)) \right)^2 \right] \end{aligned}$$

을 만족한다. 따라서

$$S(f) = \int_0^1 \int_0^x \frac{(x-t)^r}{(r-1)!} f(t) dt dx$$

라 할 때 이 문제에서의 하한은

$$e(m) = \sqrt{E_{\omega_0} \left[ (S(f) - \psi_0^*(M_m^0(f)))^2 \right]}$$

이 된다. 함수  $f$  가  $\omega_0$  에 의해 분포되고  $S(f)$  의 approximation을 구하는 문제에서는  $\psi_0^*$  이 optimal 알고리즘이다.

$S$  가 functional이기 때문에 average case 오차  $e(m)$  은,  $\omega_0$  에 의해 생성되는 reproducing kernel Hilbert space 상에서 unit ball에 대한 worst case setting일 경우  $\psi_0^*$  를 사용하여  $S$  의 근사값과 같게 된다. 이것은 다음과 같은 Sobolev space인 것이 알려져 있다. ([4] 참조) Norm이  $\|f\| = \|f'\|_2$  이고

$$W_2^1([0,1]) = f : f(0) = 0, f \text{ 는 연속이고 } f' \in L_2$$

다시 말해,

$$\begin{aligned} e(m) &= \left\{ \infty_\phi \right. \\ &= \sup \{ |S(f)| : f \in W_2^1, \|f'\|_2 \leq 1, \end{aligned}$$

$$\text{and } f(x_i) = 0, \forall i \}.$$

여기서  $m_i = (x_i + x_{i+1})/2$  이고

$$f(x) = \begin{cases} x - x_{i-1}, & \text{if } x \in [x_{i-1}, m_i], \\ x_i - x, & \text{if } x \in [m_i, x_i], \end{cases}$$

라 하면  $f \in W_2^1$ 이고 모든  $i$ 에 대해서  $f(x_i) = 0$  이 되며 또한  $\int (f')^2 = 1$ 이 된다. 그러면

$$\begin{aligned} S(f) &= \int_0^1 \int_0^1 \frac{(x-t)_+^{r-1}}{(r-1)!} f(t) dt dx \\ &= \int_0^1 f(t) \int_t^1 \frac{(x-t)^{r-1}}{(r-1)!} dx dt \\ &= \int_0^1 f(t) \frac{(1-t)^r}{r!} dt \\ &= \sum_{i=1}^m \int_{x_{i-1}}^{x_i} f(t) \frac{(1-t)^r}{r!} dt. \end{aligned}$$

구간  $[x_{i-1}, m_i]$ 에서의 적분값은

$$\begin{aligned} \int_{x_{i-1}}^{m_i} (t - x_{i-1}) \frac{(1-t)^r}{r!} dt &= \\ &= -\frac{(1-m_i)^{r+1}}{(r+1)!} \frac{x_i - x_{i-1}}{2} \\ &\quad + \frac{(1-x_{i-1})^{r+2}}{(r+2)!} - \frac{(1-m_i)^{r+2}}{(r+2)!} \end{aligned}$$

이고, 구간  $[m_i, x_i]$ 에서의 적분값은

$$\begin{aligned} \int_{m_i}^{x_i} (x_i - t) \frac{(1-t)^r}{r!} dt &= \\ &= -\frac{(1-m_i)^{r+1}}{(r+1)!} \frac{x_i - x_{i-1}}{2} \\ &\quad - \frac{(1-m_i)^{r+2}}{(r+2)!} + \frac{(1-x_i)^{r+2}}{(r+2)!} \end{aligned}$$

이다. 따라서  $\zeta(x) = (1-x)^{r+2}/(r+2)!$  이고  $h = 1/m$  이라 할 때

$$S(f) = \sum_{i=1}^m \left( \zeta(x_{i-1}) + \zeta(x_{i-1} + h) - 2\zeta\left(x_{i-1} + \frac{h}{2}\right) \right)$$

이다. 여기서  $\widetilde{x}_{i-1} \in [x_{i-1}, x_i]$ ,  $\widetilde{\widetilde{x}}_{i-1} \in [x_{i-1}, x_i]$  이라 할 때

$$\zeta(x_{i-1} + h) = \zeta(x_{i-1}) + h\zeta'(x_{i-1}) + \frac{h^2}{2}\zeta''(\widetilde{x}_{i-1}),$$

$$\zeta\left(x_{i-1} + \frac{h}{2}\right) = \zeta(x_{i-1}) + \frac{h}{2}\zeta'(x_{i-1}) + \frac{h^2}{8}\zeta''(\widetilde{\widetilde{x}}_{i-1})$$

이 됨을 알 수 있다.  $\zeta''(x) = (1-x)^r/r!$  이므로

$$\begin{aligned} &\zeta(x_{i-1}) + \zeta(x_{i-1} + h) - 2\zeta\left(x_{i-1} + \frac{h}{2}\right) \\ &= \frac{h^2}{4r!} \left( 2(1 - \widetilde{x}_{i-1})^r - (1 - \widetilde{\widetilde{x}}_{i-1})^r \right) \\ &\geq \frac{h^2}{4r!} \left( 2(1 - x_i)^r - (1 - x_{i-1})^r \right) \end{aligned}$$

이 되고, 따라서

$$\begin{aligned} S(f) &= \frac{h^2}{4r!} \left( 2 \sum_{i=1}^m (1 - x_i)^r - \sum_{i=1}^{m-1} (1 - x_i)^r \right) \\ &= \frac{h^2}{4r!} \left( \sum_{i=1}^m (1 - x_i)^r - 1 \right) = \frac{h^2}{4r!} \left( \sum_{j=0}^{m-1} x_j^r - 1 \right) \\ &\geq \frac{h}{4r!} \left( \int_0^{1-h} x^r dx - h \right) = \frac{h}{4r!} \left( \frac{(1-h)^{r+1}}{r+1} - h \right) \\ &= \frac{h}{4(r+1)!} (1 + \Theta(h)) \end{aligned}$$

이다. ■

#### IV. 결론

Infinite dimension인  $r$ -fold Wiener process를 finitely dimensional subspaces만 취급할 수 있는 컴퓨터에서 구현하기 위해서는 process  $f$  의 approximate

random process  $f_m$ 를 생성하여 이 근사함수를 이용하여 문제를 풀어야 한다. 함수를 취급하는 문제에 대한 average case 오차는 일차적으로는 information  $M_m$ 에 따라 변화하고, 이차적으로는 사용하는 algorithm  $\phi$ 에 따라 그 값이 변한다. 본 논문에서는  $m$ 개의 함수값을 information으로 사용한다고 가정할 때, 두 가지의 information  $M_m^*(f)$ 와  $M_m^{st}(f)$ 를 사용하면 Theorem1과 Theorem2에서 average case 오차가 최소화된다는 것을 보였다. 또한 Theorem3에서는 경우에 따라서는  $M_m^*(f)$ 와  $M_m^{st}(f)$  대신에  $M_m^{(r)}(f)$ 를 사용하여 average case 오차를 최소화할 수 있다는 것을 보였다.

앞으로의 과제는 위와 같은 특성을 가진 information을 생성하는 프로그램을 작성하여  $L_2$ -approximation 문제나 적분문제에 대한 average case 오차를 실험적으로 계산하는 것이다.

### 참고문헌

- [1] S. Choi and B. Hong, "An Effor of Simpson's Quadrature in the Average Case Setting," J. of Korean Math. Soc. 33 (1996), 235-247.
- [2] H. H. Kuo, "Gaussian Measures in Banach Spaces," Lecture Notes in Mathematics 463, Springer-Verlag, Berlin, 1975.
- [3] L. Plaskota, "Average Approximation and Integration in the Wiener Space with Noisy Data," J. of Complexity 8 (1992), 301-323.
- [4] K. Ritter, G. W. Wasilkowski, and H. Wozniakowski, "On Multivariage Integration for Stochastic Processes," International Series of Numerical Mathematics 112 (1993), 331-347.
- [5] J. F. Traub, G. W. Wasilkowski, and H. Wozniakowski, "Information-Based Complexity," Academic Press, New York, 1988.

### 저자 소개



#### 최 성 희

1977: 서강대학교 수학과 이학사.  
 1988: 미국 Pennsylvania State Univ. 전자계산학과 이학석사.  
 1994: 미국 Univ. of Kentucky 전자계산학과 이학박사  
 현 재: 선문대학교 컴퓨터공학과 교수  
 관심분야: 수치해석, 알고리즘  
 Email : shchoi@sunmoon.ac.kr



#### 황 석 형

1991: 강원대학교 전자계산학과 공학사.  
 1994: 일본 오사카대학교 정보공학과 공학석사.  
 1997: 일본 오사카대학교 정보공학과 공학박사  
 현 재: 선문대학교 컴퓨터공학과 교수  
 관심분야: 소프트웨어공학, 온톨로지공학, 시맨틱 웹, 빅데이터마이닝  
 Email : shwang@sunmoon.ac.kr