

相互直交化된 方向벡터를 利用한 線追跡法에 對한 研究

金 章 郁*

On the Line Search Method Using Mutually Orthonormal Directions

Chang-Wook Kim

< 目 次 >

1. 서 론	3. 반복 좌표방향벡터를 이용하는 방법
2. 상호직교화된 방향벡터를 이용한 선추적법	4. 수렴정리 참고문헌

1. 서 론

비제한적 최적화문제는 제한되어 있지 않은 함수를 최소화시키는 문제를 다루는 것이다. 비제한적 최소화문제의 해를 구하는 방법중 널리 알려진 방법들은 심플렉스방법([2]), 패턴추적법([4]), 구배법([8]), 뉴우튼방법([1]), 그리고 공액구배법([3]) 등이 있다. 이러한 방법들은 제한적 최소화문제를 푸는데 자연스럽게 이용된다([6], [7]).

본 논문에서, 상호 직교화된 방향벡터를 이용하는 선추적법과 반복 좌표방향벡터를 이용하는 방법에 대해 다룬다. 이 두 방법에 대한 알고리즘과 이 두 알고리즘을 포함할 수 있는 일반화된 알고리즘을 만들고 이에 대한 수렴정리를 확립한다.

2. 상호직교화된 방향벡터를 이용한 선추적법

이 방법은 추적방향으로 R^n 내에 있는 상호직교화된 벡터를 이용한다.

k 번째 단계에서, 우리는 한 점 x^k 와 상호직교화된 방향벡터 d_1^k, \dots, d_n^k 를 가진다. 방향벡터 d_1^k, \dots, d_n^k 에 따라 계속적으로 함수 f 를 최소화시켜서 x^{k+1} 를 얻는다. $x^{k+1} = x^k + \sum_{j=1}^k \lambda_j^k d_j^k$ 라 하자. 이때 우리는 다음과 같은 Gram-Schmidt 직교화 과정([5])에 의해 새로운 직교화된 방향벡터들의 집합을 얻는다.

* 正會員, 한국해양대학

$$a_j^{k+1} = \begin{cases} d_j^k, & \lambda_j^k = 0 \\ \sum_{i=j}^n \lambda_i^k d_i^k, & \lambda_j^k \neq 0 \end{cases} \quad (2-1)$$

$$b_j^{k+1} = \begin{cases} a_j^k, & j=1 \\ a_j^k - \sum_{i=1}^{j-1} \{(a_i^k)' d_i^{k+1}\} d_i^{k+1}, & j \geq 2 \end{cases}$$

$$d_j^{k+1} = \frac{b_j^{k+1}}{\|b_j^{k+1}\|}$$

직교화된 방향벡터를 이용한 선추적법을 다음과 같이 알고리즘화 한다.

이것은 함수 $f: \mathbf{R}^n \rightarrow \mathbf{R}$ 을 최소화하기 위한 것이다.

초기단계: $\varepsilon > 0$ 을 결정상수라 하고 좌표방향벡터인 d_1', \dots, d_n' 을 선택한다. 그리고 출발점 x^1 을 선택하여 $y_1^1 = x^1$, $k=j=1$ 라 두고 주 단계로 간다.

주 단계: 1. $\lambda \in \mathbf{R}$ 에 제한하여 $f(y_j^k + \lambda d_j^k)$ 를 최소화하는 문제의 해를 λ_j^k 라 하고, $y_j^{k+1} = y_j^k + \lambda_j^k d_j^k$ 라 하자.

만약 $j < n$ 이면 j 대신에 $j+1$ 에 대해 1 단계를 반복한다.

만약 $j = n$ 이면 step 2 로 간다.

2. $x^{k+1} = y_n^{k+1}$ 라 두자.

만약 $\|x^{k+1} - x^k\| < \varepsilon$ 이면 x^{k+1} 를 구하는 해로 한다.

만약 $\|x^{k+1} - x^k\| \geq \varepsilon$ 이면 $y_i^{k+1} = x^{k+1}$ 라 두고 k 대신에 $k+1$ 로 대체한다.

그리고 $j=1$ 라 두고 3 단계로 간다.

3. (2-1)에 의해 상호직교화된 추적방향벡터의 집합을 만들고 1 단계를 반복한다.

3. 반복 좌표방향벡터를 이용하는 방법

이 방법은 좌표축들을 추적방향으로 하여 반복적으로 시행하는 것이다. 이 방법은 다음과 같이 알고리즘화 할 수 있다.

초기단계: $\varepsilon > 0$ 을 결정상수로 취하고 d_1, \dots, d_n 을 각 좌표방향이라 하자.

x^1 을 출발점으로 하고 $y_1^1 = x^1$, $k=j=1$ 라 두어 주 단계로 간다.

주 단계: 1. $\lambda \in \mathbf{R}$ 에 제한하여 $f(y_j^k + \lambda d_j^k)$ 를 최소화하는 문제의 해를 λ_j^k 라 하고, $y_j^{k+1} = y_j^k + \lambda_j^k d_j^k$ 라 하자.

만약 $j < n$ 이면 j 대신에 $j+1$ 에 대해 1 단계를 반복한다.

만약 $j = n$ 이면 step 2 로 간다.

2. $x^{k+1} = y_n^{k+1}$ 라 두자.

만약 $\|x^{k+1} - x^k\| < \varepsilon$ 이면 x^{k+1} 를 구하는 것으로 한다.

만약 $\|x^{k+1} - x^k\| \geq \varepsilon$ 이면 $y_1^{k+1} = x^{k+1}$ 라 두고 k 대신에 $k+1$ 로 대체한다.

그리고 $j=1$ 라 두고 1 단계로 한다.

4. 수 령 정 리

상호직교화된 방향벡터를 이용한 선추적법과 반복좌표 방향벡터를 이용한 방법을 모두 포함시키는 일반화된 알고리즘을 다음과 같이 만든다.

k 번째 단계에서 한 점 x^k 와 방향벡터 d_1^k, \dots, d_n^k 를 가졌다고 하자.

방향벡터를 d_1^k, \dots, d_n^k 에 대한 조건은 각 j 에 대해 $\|d_j^k\|=1$ 이고, $|\det D^k| \geq \delta$ 인 양수 j 가 존재하는 것이다. 여기서 $D^k = (d_1^k, \dots, d_n^k)$ 이다.

x^k 를 출발점으로 하여 방향벡터 d_1^k, \dots, d_n^k 을 따라 반복적으로 최소값 $\lambda_1^k, \dots, \lambda_n^k$ 를 얻어 한 점 $x^{k+1} = x^k + D^k \lambda^k$ 를 얻는다. 여기서 $\lambda^k = (\lambda_1^k, \dots, \lambda_n^k)$ 는 각 방향벡터 d_n^k 를 따라 움직인 거리를 말한다.

$$\begin{cases} y_1^k = x^k & (4-1) \\ y_{i+1}^k = y_i^k + \lambda_i^k d_i^k, \quad i=1, \dots, n & (4-2) \\ x^{k+1} = y_{n+1}^k & (4-3) \\ f(y_i^k + \lambda_i^k d_i^k) \leq f(y_i^k + \lambda d_i^k), \quad \lambda \in \mathbf{R}, \quad i=1, \dots, n & (4-4) \end{cases}$$

새로운 D^{k+1} 는 각 j 에 대해 $\|d_j^{k+1}\|=1$ 를 만족하고, $|\det D^{k+1}| \geq \delta$ 를 만족하는 한 특수한 법칙에 의해 함수값이 생성되는 (λ^k, D^k, x^k) 에 대한 함수에 의해 결정된다.

이 알고리즘은 상호직교화된 방향벡터를 이용한 선추적법과 반복좌표 방향벡터를 이용한 방법을 일반화시킨 것이다.

다음의 보조정리는 위에서 논의된 알고리즘에 대한 수렴정리를 증명하기 위해 필요하다.

【보조정리】 함수 $f: \mathbf{R}^n \rightarrow \mathbf{R}$ 가 연속이고 $x^1 \in \mathbf{R}^n$ 이라 하자. 또 $\{d^k\}$ 를 $\|d^k\|=1$ 인 방향벡터의 수열이라 하자. 점 x^1 으로부터 출발하여 함수 f 를 x^{k-1} 으로부터 방향 d^k 에 따라 최소화하여 x^k 를 얻어 수열 $\{x^k\}$ 를 만들었다고 하자. 만약 수열 $\{x^k\}$ 가 어떤 콤팩트집합 X 에 포함되고 함수 f 가 어떠한 선상에서도 유일한 최소값을 가진다고 하면 $\lim_{k \rightarrow \infty} \|x^{k+1} - x^k\| = 0$ 이다.

【증명】 각 $x \in X$ 와 $\|d\|=1$ 인 $d \in \mathbf{R}^n$ 에 대해 $S(x, d)$ 를 모든 λ 에 대해 $f[x + s(x, d)d] \leq f(x + \lambda d)$ 가 되는 한 수라 하자. 그리고 $\varepsilon > 0$ 에 대해 $h(\varepsilon) = \inf\{f(x) - f[x + s(x, d)d] : S(x, d) \geq \varepsilon, x \in X, \|d\|=1\}$ 라 두자. 모순에 의해 각 $\varepsilon > 0$ 에 대해 $h(\varepsilon) > 0$ 임을 밝힌다.

어떤 $\varepsilon > 0$ 에 대해 $h(\varepsilon) = 0$ 라 가정하자. 하한의 정의와 X 의 콤팩트성질에 의해 $x^k \rightarrow \bar{x}$, $d^k \rightarrow \bar{d}$, $s^k = s(x^k, d^k) \rightarrow S \geq \varepsilon$, $f(x^k) - f(x^k + s^k d^k) \rightarrow 0$ 인 자연수의 무한집합 $\{k\}$ 를 얻을 수 있다.

각 λ 에 대해 $f(x^* + s^* d^*) \leq f(x^* + \lambda d^*)$ 이기 때문에 각 λ 에 대해 $f(x) = f(\bar{x} + s \bar{d}) \leq f(\bar{x} + \lambda \bar{d})$ 이다.

이것은 함수 f 가 임의의 선에 대해 유일한 최소값을 가진다는 것에 모순이 되므로 각 $\varepsilon > 0$ 에 대해 $h(\varepsilon) > 0$.

수열 $\{f(x^k)\}$ 가 아래로 유계이고 감소하므로 수열 $\{f(x^k)\}$ 는 극한값을 가진다. 따라서 각 $\varepsilon > 0$ 에 대해 유한개의 $\|x^{k+1} - x^k\|$ 만 ε 보다 크다. 따라서 $\lim_{k \rightarrow \infty} \|x^{k+1} - x^k\| = 0$.

【정리】 함수 $f : \mathbf{R}^n \rightarrow \mathbf{R}$ 가 연속적으로 미분가능이라 하고, 이 함수가 임의의 선상에서 단 하나의 최소값을 가진다고 가정하자. 또한 x^1 을 출발점으로 하여 위에서 논의된 일반화된 알고리즘에 의해 수열 $\{x^k\}$ 를 얻었다고 하자. 나아가서, 위에서 논의된 일반화된 알고리즘에 의해 얻어지는 모든 점들이 어떤 콤팩트집합에 포함된다고 가정하자. 이때, 수열 $\{x^k\}$ 의 각 집적점 \bar{x} 는 반드시 $\nabla f(\bar{x}) = 0$ 을 만족한다.

【증명】 $\{y_i^k\}$ 와 $\{\lambda_i^k\}$ 를 (4-1)에서 (4-4)까지에 따라 생성된 수열이라 하자. 이때, 보조정리에 의해 각 i 에 대해 $\lambda_i^k \rightarrow 0$ 이다.

\bar{x} 를 수열 $\{x^k\}$ 의 한 집적점이라 하자.

이때 비유계집합 K 가 존재하여 $k \rightarrow \infty$, $k \in K$ 일 때 $x^k \rightarrow \bar{x}$ 이다.

(4-1)과 (4-2)에 의해 $y_i^k = x^k + \sum_{j=1}^i \lambda_j^k d_j^k$

따라서, $k \rightarrow \infty$, $k \in K$ 일 때 $y_i^k \rightarrow \bar{x}$ 이다.

∇f 가 연속이므로 각 $\varepsilon > 0$ 에 대해 $k \in K$ 이고 $k > N$ 이면 $\|\nabla f(y_i^k) - \nabla f(\bar{x})\| < \varepsilon$ 되는 자연수 N 가 존재한다.

(4-4)에 의해 $f(y_i^k)' d_i^k = 0$.

따라서, 각 $k \in K$, $k > N$ 에 대해

$$\begin{aligned} |\nabla f(\bar{x})' d^k| &\leq \|[\nabla f(\bar{x}) - \nabla f(y_i^k)]' d_i^k\| + \|\nabla f(y_i^k)' d_i^k\| \\ &\leq \|\nabla f(\bar{x}) - \nabla f(y_i^k)\| \cdot \|d_i^k\| \\ &= \|\nabla f(\bar{x}) - \nabla f(y_i^k)\| \\ &< \varepsilon \end{aligned}$$

따라서 $k \rightarrow \infty$, $k \in K$ 일 때 $f(\bar{x})' D^k \rightarrow 0$ 이다.

D^k 의 각 행벡터들의 노름이 1이기 때문에 $k \rightarrow \infty$, $k \in K'$ 일 때 $D^k \rightarrow D$ 인 n 차 행렬 D 와 K 의 비유계부분집합 K' 가 존재한다.

$|\det D^k| \geq \delta$ 이기 때문에 $|\det D| \geq \delta$ 이다.

따라서, D 의 행벡터들은 일차독립이다.

그러므로, $\nabla f(\bar{x}) = 0$ 이다.

참 고 문 헌

- 1) E. W. Cheney and A. A. Goldstein, Newton's method for convex Programming and Tchebycheff Approximation ' Numerische Mathematik 1, 253~268, 1959.
- 2) J. W. Daniel, The conjugate gradient method for linear and nonlinear operator equations, SIAM J. Numer. Anal., 4, 10~26, 1967.
- 3) J. W. Daniel, Convergence of the conjugate gradient method with computationally convenient modifications, Numerische Mathematik, 10, 125~131, 1967.
- 4) R. Hooke and T. A. Jeeves, Direct search solution of numerical and statistical problems, J. Assoc. Comp. Mach., 8, 212~221, 1961.
- 5) S. Lang, Linear Algebra, Addison-Wesley Pub. Co., 1973.
- 6) D. G. Luenberger, Linear and Nonlinear Programming, Addison-Wesley Pub. Co., 1984.
- 7) D. M. Simmons, Nonlinear Programming for operations research, Prentice-Hall Inc., 1975.
- 8) P. Wolfe, Convergence conditions for ascent methods II: Some corrections, SIAM REVIEW, Vol. 13, No. 2, April, 1971.