

Unconstrained Optimization Problem के लिए Finite Newton Method

(A tutorial on Finite Newton method for unconstrained optimization problem)

नेहा गोयल¹, कपिल²

Neha Goyal¹, Kapil²

^{1,2}National institute of technology, kurukshetra, India

सारांश

Optimization problem के लिए न्यूटन विधि सबसे प्रसिद्ध विधि है। यह optimization प्रकार की समस्या के लिए एक iterative approach है। इस tutorial में हम unconstrained optimization problem को हल करने के लिए सीमित न्यूटन विधि पर ध्यान केंद्रित कर रहे हैं। हमने constrained optimization problem और Lagrangian multiplier method, constrained optimization problem ko unconstrained problem में परिवर्तित करने के लिए संक्षेप में चर्चा की है। उदारण स्वरूप एक unconstrained optimization problem को newton विधि से solve किया गया है।

Keywords: Optimization problem; Constraint; Lagrangian multiplier; Finite Newton method.

1. Introduction

optimization को constraint (बाधाओं) को पूरा करते हुए उपलब्ध संसाधनों के साथ सर्वोत्तम परिणामों को प्राप्त करने के रूप में परिभाषित किया गया है। हम अपने दैनिक जीवन में अधिकांश चीजों को अनुकूलित करते हैं। प्रकृति ने लगभग हर चीज को अनुकूलित किया है। यह किसी के पास जीवित रहने और सर्वोत्तम होने के बारे में है। optimization जीवन का एक तरीका है “Optimists view the proverbial glass half full and not half empty.” आशावादी किसी भी बाधा को देखते हुए, उस स्थिति से बाहर निकलने का प्रयास करता है।

गणित और कंप्यूटर विज्ञान में, एक optimization समस्या (optimization problem) वह समस्या है जो सभी संभावित समाधान (feasible solution) से सर्वोत्तम समाधान की खोज करती है। अपने सबसे सरल रूप में, इसे एक निर्धारित function के भीतर व्यवस्थित रूप से input मानों का चयन करके function के मान की गणना करके वास्तविक function को अधिकतम करने या कम करने के रूप में वर्णित किया जा सकता है।

Given a function f :

$$f: A \rightarrow \mathbb{R}, x_0 \in A$$

Either, $f(x_0) \leq f(x) \forall x \in A$ (minimization)

Or, $f(x_0) \geq f(x) \forall x \in A$ (maximization)

आम तौर पर, $A \subset \mathbb{R}^n$ constraint (समानता (equality) / असमानता (inequality)) के सेट के रूप में विशेष होता है



यहाँ $x \in A$ को सभी शर्तों (बाधाओं) को संतुष्ट करना होता है। f को objective function / loss function / लागत (cost) function/ उपयोगिता (utility) function/ fitness function के रूप में परिभाषित किया जा सकता है। optimization में यह सबसे महत्वपूर्ण बात है; कि हम चरम(extreme) पर क्या सुधारना चाहते हैं। पहचाने गए उद्देश्य के आधार पर चरम अधिकतम या न्यूनतम हो सकता है। यदि यह एक लागत है, जो कम से कम की जाती है; और यदि यह लाभ है, तो हम अधिकतम चाहते हैं, अक्सर, हम इसे एक उद्देश्य (objective function) कहते हैं क्योंकि इसे अनुकूलित करने के लिए कुछ चरों (variables) पर निर्भर होना पड़ता है। Objective function, एक या एक से अधिक optimization variables का एक function होता है। Unconstrained optimization problem कुछ अनुप्रयोगों (experiments) में सीधे उत्पन्न होती हैं लेकिन वे कई बार अप्रत्यक्ष रूप से सीमित optimization problem के सुधारों से भी उत्पन्न होती हैं। प्रायः objective function में penalized terms के साथ constraints को प्रतिस्थापित (placements of constraints with penalized terms in objective function) करके एक unconstrained optimization problem के रूप में हल करना व्यावहारिक है। यदि constraint optimization problem में केवल समानता बाधाएं (equality constraint) हैं तो "Lagrangian Multiplier" तकनीक को इसे unconstraint optimization problem में बदलने के लिए उपयोग किया जा सकता है। unconstraint optimization problem में चरों की संख्या objective function और constraints की संख्या, मूल चरों (variables) की संख्या का योग होगी। यदि optimization problem में inequality constraint है तो इसे ज्यामितीय optimal condition के संदर्भ में, KKT condition के प्रयोग से unconstrained optimization में परिवर्तित किया जा सकता।

Optimization problem:

$$\min_{x_1, x_2, \dots, x_n} f(x_1, x_2, x_3, \dots, x_n)$$

Subject to:

$$g_1(x_1, x_2, \dots, x_n) \leq 0$$

$$g_2(x_1, x_2, \dots, x_n) \leq 0$$

...

$$g_m(x_1, x_2, \dots, x_n) \leq 0$$

Lagrange multiplier तकनीक constraints में काम आने वाले variables को साथ में लेकर objective function को संशोधित करती है। कुछ non-negative Lagrange multiplier ($\lambda_j \geq 0$) की सहायता से constraints को function $f(x)$ के साथ ले आते हैं। यह augmented function L को n design variables और Lagrange multiplier की मददसे परिभाषित किया जाता है।

Lagrangian of f को निम्नलिखित तरीके से व्यक्त किया जा सकता है

$$L(x_1, x_2, \dots, x_n, \alpha_1, \alpha_2, \dots, \alpha_m) = f(x_1, x_2, \dots, x_n) + \sum_{j=1,2,3,\dots,m} \alpha_j g_j(x_1, x_2, \dots, x_n)$$

2. Newton method for unconstrained optimization problem

Isaac newton और joseph Raphson के नाम पर Newton Raphson विधि, polynomial equation की roots को खोजने के लिए एक लोकप्रिय iterative approach है। इसे न्यूटन की विधि भी कहा जाता है। Taylor series के पहली कुछ terms के पर आधारित, न्यूटन-रैफसन विधि का उपयोग अक्सर तब किया जाता है, जब दिए गए फंक्शन / समीकरण का first derivative एक बड़ी value होती है। यह अक्सर numerical methods के रूप में अन्य root finding विधियों का उपयोग कर root के अनुमानों में सुधार करने के लिए प्रयोग किया जाता है।

Newton method, दिए गए समीकरण ($f'(x) = 0$) का समाधान खोजने के लिए पुनरावृत्ति दृष्टिकोण (iterative approach) है। दिए गए समीकरण का twice differentiable होना अति आवश्यक है। यह समाधान अधिकतम, न्यूनतम या saddle बिंदु हो सकता है।

मान लीजिए, हम निम्नलिखित optimization problem को हल करना चाहते हैं

$$(P:) \min_{x \in R^n} f(x)$$

At $x = x'$, $f(x)$ को Taylor expansion से अनुमानित किया जा सकता है।

$$f(x) \approx h(x) := f(x') + \nabla f(x')^T(x - x') + \frac{1}{2}(x - x')^T H(x')(x - x')$$

उक्त expression $f(x)$ की $x = x'$, पर Taylor expansion लिखने पर प्राप्त होता है।

$\nabla f(x)$, $f(x)$ का gradient और $H(x)$, hessian है। $h(x)$ एक द्विघातीय समीकरण (quadratic equation) है; जो $\nabla h(x) = 0$ को हल करके optimize किया जाता है। Gradient of $h(x)$ को इस प्रकार दिया गया है।

$$\nabla h(x) = \nabla f(x') + H(x')(x - x')$$

इसीलिए,

$$\nabla f(x') + H(x')(x - x') = 0$$

$$x - x' = -H(x')(x - x')$$

$-H(x')(x - x')$ direction, को newton direction भी कहा जाता है।

Algorithm

Step 1 Given x_0 , set $k \rightarrow 0$ जहाँ, x_0 को randomly चुना हुआ हो सकता है अथवा x का प्रारंभिक अनुमान हो सकता है।

Step 2 $d^k = -H(x^k)^{-1} \nabla f(x^k)$. If $d^k = 0$ then stop.

Step 3 choose step size $\alpha^k = 1$

Step 4 Set $x^{k+1} \leftarrow x^k + \alpha^k d^k, k \leftarrow k + 1$. Go to step 2

Finite newton method के लिए assumption

1. $H(x^k)$ is non-singular for each iteration

2. It may be possible that $f(x^{k+1}) \leq f(x^k)$

उदाहरण 1: let $f(x) = 9x - 4\log(x - 7)$. Suppose we want to minimize the given function.

दिया हुआ:

$$f(x) = 9x - 4\log(x - 7).$$

X के लिए newton direction

$$f'(x) = 9 - \frac{4}{x}$$

$$f''(x) = \frac{4}{x^2}$$

X के लिए newton direction

$$d = -f''(x)^{-1} f'(x)$$

$$d = -\frac{x^2}{4} (9 - 4/x) = -9/4 x^2 + x$$

Newton's method will generate the sequence of iterates $\{x\}$ satisfying:

$$x^{k+1} = x^k + d$$

$$= x^k + (-f''(x^k)^{-1} f'(x^k))$$

$$= x^k + (x^k - 9/4 (x^k)^2)$$

$$= 2x^k - 9/4 (x^k)^2$$

X की प्रारंभिक विभिन्न values के लिए इस विधि द्वारा generated sequence के कुछ उदाहरण नीचे table में दिए गए हैं।



Table 2:Generated sequences for some given value of x using newton method.

Iteration	x=0.01	X=0.1	X=0	X=7	X=10	X=100
1	0.009775	0.0775	0	-103.25	-215	-22400
2	0.018895	0.10661	0	-20940	-94761	-1.1189e+09
3	0.035306	0.10249	0	-9.9574e+08	-2.0292e+10	-2.8171e+18
4	0.061663	0.050313	0	-2.2309e+18	-9.2647e+20	-1.7856e+37
5	0.094243	0.0073999	0	-1.1199e+37	-1.9313e+42	-7.1739e+74
6	0.11098	0.00012745	0	-2.8217e+74	-8.3923e+84	-1.158e+150
7	0.079442	3.657e-08	0	-1.7914e+149	-1.5847e+170	-3.0169e+300
8	0.02283	2.9976e-15	0	-7.2206e+298	-Inf	-Inf
9	0.0013075	0	0	-Inf	-Inf	-Inf
10	3.869e-06	0	0	-Inf	-Inf	-Inf

खमिया

1 सबसे पहले, function के first और second derivative दोनों की आवश्यकता है।

2. न्यूटन चरण की दिशा (newton direction) में objective का optimum की तरफ बढ़ना संभव ना हो, ऐसा हो सकता है। यह केवल तभी guaranteed है जब $f''(x)$ negative definite हो। इस कारण से, Newton-Raphson तकनीक बहुत कम ही उपयोग में लायी जाती है और दुसरे शब्दों में यह तकनीक objective function के globally concave होने पर काम आ सकती है।

संदर्भ

1. Mangasarian, O. L. (2002). A finite Newton method for classification. Optimization Methods and Software, 17(5), 913-929.
2. Fung, G., & Mangasarian, O. L. (2003). Finite Newton method for Lagrangian support vector machine classification. Neurocomputing, 55(1-2), 39-55.
3. https://en.wikipedia.org/wiki/Newton%27s_method_in_optimization
4. https://ocw.mit.edu/courses/sloan-school-of-management/15-084j-nonlinear-programming-spring-2004/lecture-notes/lec3_newton_mthd.pdf
5. <http://web.mit.edu/~jadbabai/www/EE605/lectures/unconstrained.pdf>
6. Zheng, S. (2018). A fast-iterative algorithm for support vector data description. International Journal of Machine Learning and Cybernetics, 1-15.