

Ćwiczenia 2: Metoda Spadku Newtona

Daniel Kaszyński

7-14 Marca 2023 r.

2.1 Spadek Newtona (Newton Descent)

Wzór iteracyjny metody Spadku Newtona jest następujący:

$$x_{k+1} = x_k - H_f^{-1}(x_k) \nabla f(x_k)$$

Skąd to wiemy? Rozważmy wzór aproksymacyjny Taylora:

$$f(x+h) \approx f(x) + \nabla f(x)h + \frac{1}{2}h^T H_f(x)h$$

oznacza to, że dla FOC ze względu na parametr h , tj. $\frac{df}{dh}(x+h)$ mamy

$$\frac{df}{dh}(x+h) = \nabla f(x) + H_f(x)h = 0$$

$$h = -H_f(x)^{-1} \nabla f(x)$$

Oznacza to, że optymalne przesunięcie z punktu x_k to wektor $-H_f^{-1}(x_k) \nabla f(x_k)$. Zwróćmy uwagę, że h minimalizuje wyrażenie przybliżenia wielomianu drugiego stopnia.

Zauważmy, że dla wielomianów drugiego stopnia (przyjmijmy na chwilę przypadek jednowymiarowy $f: \mathbb{R} \rightarrow \mathbb{R}$, metoda Newtona zbiega w jednej iteracji!

$$f(x) = ax^2 + bx + c?$$

$$x^{(2)} = x^{(1)} - \frac{2x^{(1)}a + b}{2a} = x^{(1)} - x^{(1)} - \frac{b}{2a} = -\frac{b}{2a}$$

Metoda Newtona przybliża wykres funkcji f wielomianem drugiego stopnia. Dla zadanego przybliżenia znajdowane jest ekstremum, do którego przechodzimy – przyjmujemy podejście iteracyjne.

Do wykorzystania metody Newtona potrzebna jest znajomość macierzy Hessianu w dowolnym punkcie f . W tym celu stosujemy przybliżenie numeryczne, którego osiągnęliśmy przy pomocy poniższej funkcji:

```

1 num_hessian <- function(f, x, h=10^-3){
2   #' Numerical hessian
3   #'
4   #' @description Numerical (central) hessian calculation
5   #'
6   #' @param f function that is subject to be calculate hessian
7   #' @param x point at with the gradient is calculated (must be compliant with
8   #' f function).
9   #' @param h finite difference (numerical perturbation scalar).
10  #'
11  #' @return hessian matrix of f.

```

```

12
13 n <-length(x)
14 H <- matrix(NA, nrow=n, ncol=n)
15 e <- diag(n)
16 for(i in 1:n){
17   for(j in 1:n){
18     if(i>j){
19       H[i,j] <- H[j,i]
20     }else{
21       H[i,j] <- (f(x+e[i,]*h+e[,j]*h)-f(x-e[i,]*h+e[,j]*h)
22                 -f(x+e[i,]*h-e[,j]*h)+f(x-e[i,]*h-e[,j]*h)) / (4*h^2)
23     }
24   }
25 }
26 return(H)
27 }

```

Listing 1: Implementacja algorytmu spadku gradientowego

Poniżej przedstawiono przykładową implementację metody Newtona.

```


1 source('num_grad.R')
2 source('num_hessian.R')
3
4 newton_descent <- function(f, x, max_iter=100){
5   #' Newton Descent solver
6   #'
7   #' @description Newton Descent Solver (for R^n -> R functions)
8   #'
9   #' @param f objective function that is subject to be optimize.
10  #' @param x initial solution that is scalar/vector (must be compliant with
11  #' f function).
12  #' @param max_iter maximum number of iterations used in the solver.
13  #'
14  #' @return list with the optimization results.
15
16  start_t <- Sys.time()
17  n<-length(x)
18  out <- list(x_opt=x,
19             f_opt=f(x),
20             x_hist=matrix(NA, nrow=max_iter, ncol=n),
21             f_hist=rep(NA, max_iter),
22             a=rep(NA, max_iter),
23             t_eval=NA)
24
25  # Assign first solution as a x0 imputed to the function
26  out$x_hist[1,] <- x
27  out$f_hist[1] <- f(x)
28  out$a[1] <- NA
29
30  xk <- x
31  for(k in 2:max_iter){
32    G <- num_grad(f, xk)
33    H <- num_hessian(f, xk)
34    if(abs(det(H)) < 10^-3) H <- H+diag(n)*10^-3
35
36    xk <- xk - solve(H)%*%G
37    if(f(xk) < f(x)){
38      x <- xk
39    }
40    out$x_hist[k,] <- xk
41    out$f_hist[k] <- f(xk)
42  }
43

```

```
44 # Assign optimal solution to output
45 out$x_opt <- x
46 out$f_opt <- f(x)
47 out$t_eval <- Sys.time() - start_t
48 return(out)
49 }
```

Listing 2: Kod wykorzystany do porównania działania algorytmu GD


Poniżej przedstawiono porównanie metod: Spadek Gradientowy, Najszybszy Spadek, oraz Spadek Newtona.

Rysunek 2.1: Trajektoria wektora x w kolejnych iteracjach algorytmów GD, SD, ND

Poniżej porównano wartości funkcji celu, dla poszczególnych solverów optymalizacyjnych.

Bibliografia

[KW19] M. KOCHENDERFER and T. WHEELER, “Algorithms for optimization, “*Mit Press*, 2019.



Rysunek 2.2: Wartość funkcji celu w kolejnych iteracjach algorytmów GD, SD i ND SD