

Optymalizacja wieloetapowa



Optymalizacja wieloetapowa

$$x_1^*, x_2^*, \dots, x_S^* \rightarrow F(x_1^*, x_2^*, \dots, x_S^*) = \min_{x_1, x_2, \dots, x_S \in \mathcal{D}_x} F(x_1, x_2, \dots, x_S)$$

$$\mathcal{D}_x = (x_1, x_2, \dots, x_S)$$

$$\left\{ \begin{aligned} [x_1 \ x_2 \ \dots \ x_S]^T \in \mathcal{R}^S : \varphi_l(x_1, x_2, \dots, x_S) = 0, l = 1, 2, \dots, L, \\ \psi_m(x_1, x_2, \dots, x_S) \leq 0, m = 1, 2, \dots, M \end{aligned} \right\}$$

Powyższe zadanie można rozwiązać krok po kroku optymalizując po jednej zmiennej i uzależniając od pozostałych.

Przyjmijmy oznaczenia:

$$F \equiv F_S, \quad \varphi_l \equiv \varphi_{lS}, l = 1, 2, \dots, L, \quad \psi_m = \psi_{mS}, m = 1, 2, \dots, M \quad \mathcal{D}_x \equiv \mathcal{D}_{x_S}$$

Optymalizacja wieloetapowa

Krok 1.

$$x_S^* = G_S(x_1, \dots, x_{S-1}) \rightarrow F_S(x_1, x_2, \dots, x_S^*) = \min_{x_S \in \mathcal{D}_{xS}} F_S(x_1, x_2, \dots, x_S)$$

Wartość funkcji celu w punkcie optymalnym:

$$F_{S-1}(x_1, x_2, \dots, x_{S-1}) \stackrel{\Delta}{=} F_S(x_1, x_2, \dots, x_S^*) = F_S(x_1, x_2, \dots, G_S(x_1, \dots, x_{S-1}))$$

Ograniczenia w punkcie optymalnym:

$$\begin{aligned} \mathcal{D}_{xS-1}(x_1, \dots, x_{S-1}) &\stackrel{\Delta}{=} \mathcal{D}_{xS}(x_1, \dots, x_{S-1}, x_S^* = G_S(x_1, \dots, x_{S-1})) = \\ &\left\{ \begin{aligned} &[x_1 \ x_2 \ \cdots \ x_{S-1}]^T \in \mathcal{R}^{S-1} : \\ &\varphi_{lS}(x_1, x_2, \cdots, G_S(x_1, \dots, x_{S-1})) = \varphi_{lS-1}(x_1, x_2, \cdots, x_{S-1}) = 0, \ l = 1, 2, \dots, L, \\ &\psi_{mS}(x_1, x_2, \cdots, G_S(x_1, \dots, x_{S-1})) = \psi_{mS-1}(x_1, x_2, \cdots, x_{S-1}) \leq 0, \ m = 1, 2, \dots, M \end{aligned} \right\} \end{aligned}$$

Optymalizacja wieloetapowa

Krok 2.

$$x_{S-1}^* = G_{S-1}(x_1, \dots, x_{S-2}) \rightarrow F_{S-1}(x_1, x_2, \dots, x_{S-1}^*) = \min_{x_{S-1} \in \mathcal{D}_{xS-1}} F_{S-1}(x_1, x_2, \dots, x_{S-1})$$

Wartość funkcji celu w punkcie optymalnym:

$$F_{S-2}(x_1, x_2, \dots, x_{S-2}) \stackrel{\Delta}{=} F_{S-1}(x_1, x_2, \dots, x_{S-1}^*) = F_{S-1}(x_1, x_2, \dots, G_{S-1}(x_1, \dots, x_{S-2}))$$

Ograniczenia w punkcie optymalnym:

$$\mathcal{D}_{xS-2}(x_1, \dots, x_{S-2}) \stackrel{\Delta}{=} \mathcal{D}_{xS-1}(x_1, \dots, x_{S-2}, x_{S-1}^* = G_{S-1}(x_1, \dots, x_{S-2})) =$$

$$\left\{ \begin{array}{l} [x_1 \ x_2 \ \cdots \ x_{S-2}]^T \in \mathcal{R}^{S-2} : \\ \varphi_{lS-1}(x_1, x_2, \dots, G_{S-1}(x_1, \dots, x_{S-2})) = \varphi_{lS-2}(x_1, x_2, \dots, x_{S-2}) = 0, \ l = 1, 2, \dots, L, \\ \psi_{mS-1}(x_1, x_2, \dots, G_{S-1}(x_1, \dots, x_{S-2})) = \psi_{mS-2}(x_1, x_2, \dots, x_{S-2}) \leq 0, \ m = 1, 2, \dots, M \end{array} \right\}$$

⋮

Optymalizacja wieloetapowa

⋮

Krok S-1.

$$x_2^* = G_2(x_1) \rightarrow F_2(x_1, x_2^*) = \min_{x_2 \in \mathcal{D}_{x_2}} F_2(x_1, x_2)$$

Wartość funkcji celu w punkcie optymalnym:

$$F_1(x_1) \stackrel{\Delta}{=} F_2(x_1, x_2^*) = F_2(x_1, G_2(x_1))$$

Ograniczenia w punkcie optymalnym:

$$\mathcal{D}_{x_1}(x_1) \stackrel{\Delta}{=} \mathcal{D}_{x_2}(x_1, x_2^* = G_2(x_1)) = \left\{ \begin{array}{l} x_1 \in \mathcal{R}: \\ \varphi_{l2}(x_1, G_2(x_1)) = \varphi_{l1}(x_1) = 0, l = 1, 2, \dots, L, \\ \psi_{m2}(x_1, G_2(x_1)) = \psi_{m1}(x_1) \leq 0, m = 1, 2, \dots, M \end{array} \right\}$$

Optymalizacja wieloetapowa

Krok S.

$$x_1^* \rightarrow F_1(x_1^*) = \min_{x_1 \in \mathcal{D}_{x_1}} F_1(x_1)$$

Teraz możemy powrócić do zależności „G” wyznaczonych w poprzednich krokach

$$x_1^*$$

$$x_2^* = G_2(x_1^*)$$

$$\vdots$$

$$x_{S-1}^* = G_{S-1}(x_1^*, x_2^*, \dots, x_{S-2}^*)$$

$$x_S^* = G_S(x_1^*, x_2^*, \dots, x_{S-1}^*)$$

Optymalizacja wieloetapowa

Przykład:

$$F(x_1, x_2) = x_1^2 + x_1 x_2 + x_2^2 = F_2(x_1, x_2)$$

Krok 1.

$$x_2^* = G_2(x_1) \rightarrow F_2(x_1, x_2^*) = \min_{x_2} \{ x_1^2 + x_1 x_2 + x_2^2 \}$$

$$\frac{\partial}{\partial x_2} F_2(x_1, x_2^*) = x_1 + 2x_2^* = 0 \Rightarrow x_2^* = -\frac{1}{2}x_1 = G_2(x_1)$$

$$F_1(x_1) \stackrel{\Delta}{=} F(x_1, x_2^*) = F(x_1, G_2(x_1)) = (x_1)^2 + x_1 \left(-\frac{1}{2}x_1 \right) + \left(-\frac{1}{2}x_1 \right)^2$$

$$F_1(x_1) = \frac{3}{4}x_1^2$$

Optymalizacja wieloetapowa

Krok 2.

$$x_1^* \Rightarrow F_1(x_1) = \min_{x_1} \left\{ \frac{3}{4} x_1^2 \right\}$$

$$\frac{d}{dx_1} F_1(x_1) = 2 \frac{3}{4} x_1 = 0 \Rightarrow x_1^* = 0$$

Teraz wracamy:

$$x_1^* = 0$$

$$x_2^* = G_2(x_1^*) = -\frac{1}{2} x_1^* = 0$$

Programowanie dynamiczne




Programowanie dynamiczne

Proces dynamiczny: $y_{n+1} = P(y_n, x_n)$, y_0 n - takt $n = 1, 2, \dots, N$

x_n - decyzja w n - tym takcie

y_n - stan procesu w n - tym takcie



Zadanie decyzyjne: znaleźć ciąg decyzji: $x_0^*, x_1^*, \dots, x_{N-1}^*$,

Po co? Po N krokach zamierzamy coś osiągnąć np.: $y_N = y^*$ - zadany stan,

Przy czym wskaźnik $Q(x_0, \dots, x_{N-1}, y_1, \dots, y_N)$ przyjmuje wartość minimalną.

Programowanie dynamiczne

Określmy przykładowe oceny ciągu decyzji oraz efektów decyzji

$$Q(x_0, x_1, \dots, x_{N-1}, y_1, y_2, \dots, y_N)$$

Np.:

$$Q(x_0, x_1, \dots, x_{N-1}, y_1, y_2, \dots, y_N) = \sum_{n=0}^{N-1} x_n^2, \quad y_N = y^*$$

$$Q(x_0, x_1, \dots, x_{N-1}, y_1, y_2, \dots, y_N) = \sum_{n=0}^{N-1} x_n^2, \quad \underline{y} \leq y_N \leq \bar{y}$$

$$Q(x_0, x_1, \dots, x_{N-1}, y_1, y_2, \dots, y_N) = \sum_{n=1}^{N-1} (y_n - y_n^*), \quad 0 \leq x_n \leq \bar{x}$$

$$Q(x_0, x_1, \dots, x_{N-1}, y_1, y_2, \dots, y_N) = \sum_{n=0}^{N-1} A_{n+1}(x_n, y_{n+1}), \quad \text{przy ograniczeniach } x_n \text{ i } y_n$$

Programowanie dynamiczne

Można postąpić w następujący sposób:

$$y_0$$

$$y_1 = P(y_0, x_0)$$

$$y_2 = P(y_1, x_1) = P(P(y_0, x_0), x_1) \stackrel{\Delta}{=} P_1(y_0, x_0, x_1)$$

$$\vdots$$

$$y_N = P(y_{N-1}, x_{N-1}) = P(P(y_{N-2}, x_{N-2}), x_{N-1}) = \overset{y_{n+1}=P(y_n, x_n)}{\dots} = P_{N-1}(y_0, x_0, x_1, \dots, x_N)$$

Po podstawieniu do $Q(\cdot)$ otrzymujemy:

$$Q(x_0, x_1, \dots, x_{N-1}, y_1, y_2, \dots, y_N) = \sum_{n=0}^{N-1} A_{n+1}(x_n, y_{n+1}) \stackrel{\Delta}{=} F(y_0, x_0, x_1, \dots, x_{N-1})$$

Programowanie dynamiczne

Ponieważ:

$$Q(x_0, x_1, \dots, x_{N-1}, y_1, y_2, \dots, y_N) = \sum_{n=0}^{N-1} A_{n+1}(x_n, y_{n+1}) \stackrel{\Delta}{=} F(y_0, x_0, x_1, \dots, x_{N-1})$$



Zadanie optymalizacji:

$$x_0^*, x_1^*, \dots, x_{N-1}^* \rightarrow Q(x_0^*, x_1^*, \dots, x_{N-1}^*, y_1, y_2, \dots, y_N) = \min_{x_0, x_1, \dots, x_{N-1}} Q(x_0, x_1, \dots, x_{N-1}, y_1, y_2, \dots, y_N)$$

Jest równoważne zadaniu:

$$x_0^*, x_1^*, \dots, x_{N-1}^* \rightarrow F(y_0, x_0^*, x_1^*, \dots, x_{N-1}^*) = \min_{x_0, x_1, \dots, x_{N-1}} F(y_0, x_0, x_1, \dots, x_{N-1})$$

Do rozwiązania tego zadania można zastosować podejście wieloetapowe.



$$Q(x_0, x_1, \dots, x_{N-1}, y_1, y_2, \dots, y_N) = \sum_{n=0}^{N-1} A_{n+1}(x_n, y_{n+1}) \stackrel{\Delta}{=} F(y_0, x_0, x_1, \dots, x_{N-1})$$

Programowanie dynamiczne

$$Q(x_0, x_1, \dots, x_{N-1}, y_1, y_2, \dots, y_N) = \sum_{n=0}^{N-1} A_{n+1}(x_n, y_{n+1}) \stackrel{\Delta}{=} F(y_0, x_0, x_1, \dots, x_{N-1})$$

Uwaga:

Ostatni stan y_N zależy od decyzji x_{N-1} oraz stanu y_{N-1} , który zależy od poprzednich decyzji $x_0, x_1, \dots, x_{N-2}$.



Poprzedni stan y_{N-1} zależy od decyzji x_{N-2} oraz stanu y_{N-2} , który zależy od poprzednich decyzji $x_0, x_1, \dots, x_{N-3}$.

⋮

Stan y_2 zależy od decyzji x_1 oraz stanu y_1 , który zależy od poprzednich decyzji x_0, x_1 .

Stan y_1 zależy od decyzji x_0 oraz stanu y_0 , który to wartości są znane.

Do rozwiązania zadania optymalizacji powyższej funkcji można zastosować podejście wieloetapowe. Ze względu na specyficzną postać kryterium (suma funkcji decyzji x_n oraz stanu y_{n+1} w kolejnych taktach. Optymalizując kolejno od ostatniego składnika uzależniamy rozwiązanie od poprzedniego stanu i poprzednich decyzji.



$$Q(x_0, x_1, \dots, x_{N-1}, y_1, y_2, \dots, y_N) = \sum_{n=0}^{N-1} A_{n+1}(x_n, y_{n+1}) \stackrel{\Delta}{=} F(y_0, x_0, x_1, \dots, x_{N-1})$$

Programowanie dynamiczne

$$Q(x_0, x_1, \dots, x_{N-1}, y_1, y_2, \dots, y_N) = \sum_{n=0}^{N-1} A_{n+1}(x_n, y_{n+1})$$

Krok 1. $x_{N-1}^* \rightarrow \min_{x_{N-1}} A_N(x_{N-1}, y_N)$

Wiemy że: $y_N = P(y_{N-1}, x_{N-1})$



$$x_{N-1}^* = G_{N-1}(y_{N-1}) \rightarrow \min_{x_{N-1}} A_N(x_{N-1}, P(y_{N-1}, x_{N-1}))$$

$$V_{N-1}(y_{N-1}) \stackrel{\Delta}{=} \min_{x_{N-1}} A_N(x_{N-1}, P(y_{N-1}, x_{N-1})) =$$

$$= A_N(x_{N-1}^*, P(y_{N-1}, x_{N-1}^*)) = A_N(G_{N-1}(y_{N-1}), P(y_{N-1}, G_{N-1}(y_{N-1})))$$

Programowanie dynamiczne

Krok 2. $x_{N-2}^* \rightarrow \min_{x_{N-2}} \{A_{N-1}(x_{N-2}, y_{N-1}) + V_{N-1}(y_{N-1})\}$

Wiemy że: $y_{N-1} = P(y_{N-2}, x_{N-2})$

$$x_{N-2}^* = G_{N-2}(y_{N-2}) \rightarrow \min_{x_{N-2}} \{A_{N-1}(x_{N-2}, P(y_{N-2}, x_{N-2})) + V_{N-1}(P(y_{N-2}, x_{N-2}))\}$$

$$\begin{aligned} V_{N-2}(y_{N-2}) &\stackrel{\Delta}{=} \min_{x_{N-2}} \{A_{N-1}(x_{N-2}, P(y_{N-2}, x_{N-2})) + V_{N-1}(P(y_{N-2}, x_{N-2}))\} = \\ &= \{A_{N-1}(x_{N-2}^*, P(y_{N-2}, x_{N-2}^*)) + V_{N-1}(P(y_{N-2}, x_{N-2}^*))\} = \\ &= A_{N-1}(G_{N-2}(y_{N-2}), P(y_{N-2}, G_{N-2}(y_{N-2}))) + V_{N-1}(P(y_{N-2}, G_{N-2}(y_{N-2}))) \end{aligned}$$


⋮

Programowanie dynamiczne

Krok N-1.

$$x_1^* \rightarrow \min_{x_1} \{A_2(x_1, y_2) + V_2(y_2)\}$$

Wiemy że:

$$y_2 = P(y_1, x_1)$$


$$x_1^* = G_1(y_1) \rightarrow \min_{x_1} \{A_2(x_1, P(y_1, x_1)) + V_2(P(y_1, x_1))\}$$

$$V_1(y_1) \stackrel{\Delta}{=} \min_{x_1} \{A_2(x_1, P(y_1, x_1)) + V_2(P(y_1, x_1))\} =$$

$$= A_2(x_1^*, P(y_1, x_1^*)) + V_2(P(y_1, x_1^*))$$

$$= A_2(G_1(y_1), P(y_1, G_1(y_1))) + V_2(P(y_1, G_1(y_1)))$$

Programowanie dynamiczne

Krok N.

$$x_0^* \rightarrow \min_{x_0} \{A_1(x_0, y_1) + V_1(y_1)\}$$

Wiemy że:

$$y_1 = P(y_0, x_0)$$

$$x_0^* = G_0(y_0) \rightarrow \min_{x_0} \{A_1(x_0, P(y_0, x_0)) + V_1(P(y_0, x_0))\}$$

y_0 jest znaną wartością i teraz możemy wyliczyć kolejne wartości decyzji $x_0^*, x_1^*, \dots, x_{N-1}^*$,



$$x_0^* = G_0(y_0) \rightarrow y_1 = P(y_0, x_0^*)$$

$$x_1^* = G_1(y_1) \rightarrow y_2 = P(y_1, x_1^*)$$

$\vdots$

$$x_{N-2}^* = G_{N-2}(y_{N-2}) \rightarrow y_{N-1} = P(y_{N-2}, x_{N-2}^*)$$

$$x_{N-1}^* = G_{N-1}(y_{N-1}) \rightarrow y_N = P(y_{N-1}, x_{N-1}^*)$$



$$Q(x_0, x_1, \dots, x_{N-1}, y_1, y_2, \dots, y_N) = \sum_{n=0}^{N-1} A_{n+1}(x_n, y_{n+1}) \stackrel{\Delta}{=} F(y_0, x_0, x_1, \dots, x_{N-1})$$

Programowanie dynamiczne

Przykład: $y_{n+1} = P(y_n, x_n) = 2y_n + x_n$, $y_0 = 0$

$$\begin{aligned} Q(x_0, x_1, y_1, y_2) &= \sum_{n=0}^1 A_{n+1}(x_n, y_{n+1}) = \sum_{n=0}^1 (x_n^2 + (y_{n+1} - 5)^2) = \\ &= (x_0^2 + (y_1 - 5)^2) + (x_1^2 + (y_2 - 5)^2) \end{aligned}$$

Krok 1.

$$x_1^* \rightarrow \min_{x_1} (x_1^2 + (y_2 - 5)^2)$$

$$y_2 = 2y_1 + x_1$$

$$x_1^* = G_1(y_1) \rightarrow \min_{x_1} (x_1^2 + (2y_1 + x_1 - 5)^2)$$

$$2x_1^* + 2(2y_1 + x_1^* - 5) = 0 \Rightarrow x_1^* = G_1(y_1) = \frac{5}{2} - y_1$$

$$V_1(y_1) = \left(\frac{5}{2} - y_1\right)^2 + \left(2y_1 + \frac{5}{2} - y_1 - 5\right)^2 = 2\left(y_1 - \frac{5}{2}\right)^2$$

Programowanie dynamiczne

$$\text{Krok 2. } x_0^* \rightarrow \min_{x_0} \left\{ \left(x_0^2 + (y_1 - 5)^2 \right) + 2 \left(y_1 - \frac{5}{2} \right)^2 \right\}$$

$$y_1 = 2y_0 + x_0$$

$$x_0^* = G_0(y_0) \rightarrow \min_{x_0} \left\{ \left(x_0^2 + (2y_0 + x_0 - 5)^2 \right) + 2 \left(2y_0 + x_0 - \frac{5}{2} \right)^2 \right\}$$

$$2x_0^* + 2(2y_0 + x_0^* - 5) + 4 \left(2y_0 + x_0 - \frac{5}{2} \right) = 0 \Rightarrow x_0^* = G_0(y_0) = \frac{15}{8} - \frac{3}{2}y_0 = \frac{15}{8}$$

Teraz wracamy:

$$x_0^* = \frac{15}{8} \rightarrow y_1 = 2 \times 0 + \frac{15}{8} = \frac{15}{8}$$

$$x_1^* = \frac{5}{2} - \frac{15}{8} = \frac{5}{8} \rightarrow y_1 = 2 \times 0 + \frac{5}{8} = \frac{5}{8}$$

Przypadek liniowo – kwadratowy

Algorytm rekurencyjny

$$Q_N(\theta) = \sum_{n=1}^N (y_n - \bar{y}_n)^2 = \sum_{n=1}^N (y_n - \theta^T \varphi(u_n))^2 \quad U_N = [u_1 \quad u_2 \quad \cdots \quad u_N], \quad Y_N = [y_1 \quad y_2 \quad \cdots \quad y_N]$$

Wektor parametrów θ_N^* wyznaczamy na podstawie N pomiarów

$$\theta_N^* = \left[\sum_{n=1}^N \varphi(u_n) \varphi^T(u_n) \right]^{-1} \times \sum_{n=1}^N y_n \varphi(u_n)$$

Pojawia się nowy $N+1$ pomiar u_{N+1}, y_{N+1}

Jak wyznaczyć (poprawić) parametr korzystając z nowego pomiaru?

$$\begin{aligned} \theta_{N+1}^* &= A(\theta_N^*, u_{N+1}, y_{N+1}) \\ Q_{N+1}(\theta) &= \sum_{n=1}^{N+1} (y_n - \bar{y}_n)^2 = \sum_{n=1}^{N+1} (y_n - \theta^T \varphi(u_n))^2 \\ \theta_{N+1}^* &= \left[\sum_{n=1}^{N+1} \varphi(u_n) \varphi^T(u_n) \right]^{-1} \times \sum_{n=1}^{N+1} y_n \varphi(u_n) = \\ &= \left[\sum_{n=1}^N \varphi(u_n) \varphi^T(u_n) + \varphi(u_{N+1}) \varphi^T(u_{N+1}) \right]^{-1} \times \left[\sum_{n=1}^N y_n \varphi(u_n) + y_{N+1} \varphi(u_{N+1}) \right] \end{aligned}$$

Przypadek liniowo – kwadratowy

Algorytm rekurencyjny

Przydatne przekształcenia algebraiczne:

$$(\mathbf{A} + \mathbf{B}\mathbf{D}^{-1}\mathbf{C})^{-1} = \mathbf{A}^{-1} - \mathbf{A}^{-1}\mathbf{B}(\mathbf{D} + \mathbf{C}\mathbf{A}^{-1}\mathbf{B})^{-1}\mathbf{C}\mathbf{A}^{-1}$$

$\mathbf{B} = \varphi$ – wektor kolumnowy

$$\mathbf{D}^{-1} = 1$$

$$\mathbf{C} = \varphi^T$$

$$(\mathbf{A} + \varphi\varphi^T)^{-1} = \mathbf{A}^{-1} - \mathbf{A}^{-1}\varphi(1 + \varphi^T\mathbf{A}^{-1}\varphi)^{-1}\varphi^T\mathbf{A}^{-1}$$

$$\mathbf{D}^{-1} = -1$$

$$(\mathbf{A} - \varphi\varphi^T)^{-1} = \mathbf{A}^{-1} + \mathbf{A}^{-1}\varphi(1 - \varphi^T\mathbf{A}^{-1}\varphi)^{-1}\varphi^T\mathbf{A}^{-1}$$

Przypadek liniowo – kwadratowy

Algorytm rekurencyjny

Oznaczmy przez: $\varphi_n = \varphi(u_n)$, $n = 1, 2, \dots, N + 1$

$$\begin{aligned} \left(\sum_{n=1}^{N+1} \varphi_n \varphi_n^T \right)^{-1} &= \left(\sum_{n=1}^N \varphi_n \varphi_n^T + \varphi_{N+1} \varphi_{N+1}^T \right)^{-1} = \\ &= \left(\sum_{n=1}^N \varphi_n \varphi_n^T \right)^{-1} - \left(\sum_{n=1}^N \varphi_n \varphi_n^T \right)^{-1} \frac{\varphi_{N+1} \varphi_{N+1}^T}{1 + \varphi_{N+1}^T \left(\sum_{n=1}^N \varphi_n \varphi_n^T \right)^{-1} \varphi_{N+1}} \left(\sum_{n=1}^N \varphi_n \varphi_n^T \right)^{-1} \end{aligned}$$

Niech: $P_N = \left(\sum_{n=1}^N \varphi_n \varphi_n^T \right)^{-1}$

Powyższe przyjmuje postać:

$$P_{N+1} = P_N - P_N \frac{\varphi_{N+1} \varphi_{N+1}^T}{1 + \varphi_{N+1}^T P_N \varphi_{N+1}} P_N$$

Przypadek liniowo – kwadratowy

Algorytm rekurencyjny

$$\begin{aligned}
 \theta_{N+1}^* &= \left(P_N - P_N \frac{\varphi_{N+1} \varphi_{N+1}^T}{1 + \varphi_{N+1}^T P_N \varphi_{N+1}} P_N \right) \left(\sum_{n=1}^N \varphi_n y_n + \varphi_{N+1} y_{N+1} \right) = \\
 &= P_N \sum_{n=1}^N \varphi_n y_n + P_N \varphi_{N+1} y_{N+1} - \frac{P_N \varphi_{N+1} \varphi_{N+1}^T P_N}{1 + \varphi_{N+1}^T P_N \varphi_{N+1}} \sum_{n=1}^N \varphi_n y_n - \frac{P_N \varphi_{N+1} \varphi_{N+1}^T P_N \varphi_{N+1} y_{N+1}}{1 + \varphi_{N+1}^T P_N \varphi_{N+1}} = \\
 &= P_N \sum_{n=1}^N \varphi_n y_n + \frac{P_N \varphi_{N+1} y_{N+1} + P_N \varphi_{N+1} y_{N+1} \varphi_{N+1}^T P_N \varphi_{N+1} - P_N \varphi_{N+1} y_{N+1} \varphi_{N+1}^T P_N \varphi_{N+1} - P_N \varphi_{N+1} \varphi_{N+1}^T P_N \sum_{n=1}^N \varphi_n y_n}{1 + \varphi_{N+1}^T P_N \varphi_{N+1}} = \\
 &= P_N \sum_{n=1}^N \varphi_n y_n + \frac{P_N \varphi_{N+1} y_{N+1} - P_N \varphi_{N+1} \varphi_{N+1}^T P_N \sum_{n=1}^N \varphi_n y_n}{1 + \varphi_{N+1}^T P_N \varphi_{N+1}} y = \\
 &= P_N \sum_{n=1}^N \varphi_n y_n + \frac{P_N \varphi_{N+1} y_{N+1}}{1 + \varphi_{N+1}^T P_N \varphi_{N+1}} \left(y_{N+1} + \varphi_{N+1}^T P_N \sum_{n=1}^N \varphi_n y_n \right) \\
 &= \theta_N^* + K_{N+1} (y_{N+1} - \varphi_{N+1}^T \theta_N)
 \end{aligned}$$

gdzie: $K_{N+1} = \frac{P_N \varphi_{N+1}}{1 + \varphi_{N+1}^T P_N \varphi_{N+1}}$

Przypadek liniowo – kwadratowy

Algorytm rekurencyjny

Podsumowując, otrzymujemy następujący algorytm


$$\theta_N^* = \left(\sum_{n=1}^N \varphi_n \varphi_n^T \right)^{-1} \sum_{n=1}^N \varphi_n y_n = P_N \sum_{n=1}^N \varphi_n y_n, \text{ gdzie: } P_N = \left(\sum_{n=1}^N \varphi_n \varphi_n^T \right)^{-1}$$

$$\theta_{N+1}^* = A(\theta_N, u_{N+1}, y_{N+1}) = \theta_N^* + K_{N+1} [y_{N+1} - \varphi(u_{N+1})^T \theta_N^*]$$


$$K_{N+1} = \frac{P_N \varphi(u_{N+1})}{1 + \varphi(u_{N+1})^T P_N \varphi(u_{N+1})}$$

$$P_{N+1} = P_N - \frac{P_N \varphi(u_{N+1}) \varphi(u_{N+1})^T P_N}{1 + \varphi(u_{N+1})^T P_N \varphi(u_{N+1})}$$

Sieć wielowarstwowa



Model neuronu (uproszczenie)




$$y = \phi\left(\sum_{s=1}^s \theta_s u^{(s)} + \theta_0\right) = \phi(\theta^T \varphi(u)) \quad \Phi - \text{funkcja aktywacji}$$

Funkcja aktywacji


$$\phi(\kappa) = \begin{cases} 1 & \text{dla } \kappa > 0 \\ -1 & \text{dla } \kappa \leq 0 \end{cases}$$

Perceptron



$$\phi(\kappa) = \kappa$$


Adaline
Adaptive Linear Neuron



$$\phi(\kappa) = \frac{1}{1 + e^{-\beta\kappa}}$$

$$\phi(\kappa) = \tanh(\beta\kappa) = \frac{1 - e^{-\beta\kappa}}{1 + e^{-\beta\kappa}}$$


Neuron sigmoidalny



Uczenie neuronu

Neuron Adaline (Adaptive Linear Neuron)

$$\phi(\kappa) = \kappa$$



$$y = \phi\left(\sum_{s=1}^S \theta_s u^{(s)} + \theta_0\right) = \phi(\theta^T \varphi(u)) = \theta^T \varphi(u)$$

$$\theta = [\theta_0 \ \theta_1 \ \dots \ \theta_S]^T \quad \varphi(u) = [1 \ u^{(1)} \ \dots \ u^{(S)}]^T$$

Uczenie: $[u_1 \ u_2 \ \dots \ u_N] = U_N \quad [y_1 \ y_2 \ \dots \ y_N] = Y_N$

$$Q_N(\theta) = \sum_{n=1}^N (y_n - \bar{y}_n)^2 = \sum_{n=1}^N (y_n - \theta^T \varphi(u_n))^2 \quad \text{To już było}$$

$$\theta_N^* = \left[\sum_{n=1}^N \varphi(u_n) \varphi^T(u_n) \right]^{-1} \times \sum_{n=1}^N y_n \varphi(u_n)$$

lub rekurencyjnie

Algortm rekurencyjny


$$\theta_{N+1}^* = A(\theta_N^*, u_{N+1}, y_{N+1}) = \theta_N^* + K_{N+1} [y_{N+1} - \varphi(u_{N+1})^T \theta_N^*]$$

$$K_{N+1} = \frac{P_N \varphi(u_{N+1})}{1 + \varphi(u_{N+1})^T P_N \varphi(u_{N+1})}$$

$$P_{N+1} = P_N - \frac{P_N \varphi(u_{N+1}) \varphi(u_{N+1})^T P_N}{1 + \varphi(u_{N+1})^T P_N \varphi(u_{N+1})}$$

Uczenie neuronu

Podobnie jak neuron Adaline (Adaptive Linear Neuron) $\phi(\kappa)$ - wzajemnie jednoznaczna



$$y = \phi\left(\sum_{s=1}^S \theta_s u^{(s)} + \theta_0\right) = \phi(\theta^T \varphi(u))$$

$$\theta = [\theta_0 \ \theta_1 \ \dots \ \theta_s]^T \quad \varphi(u) = [1 \ u^{(1)} \ \dots \ u^{(s)}]^T$$

Uczenie: $[u_1 \ u_2 \ \dots \ u_N] = U_N \quad [y_1 \ y_2 \ \dots \ y_N] = Y_N$

$$Q_N(\theta) = \sum_{n=1}^N (\kappa_n - \bar{\kappa}_n)^2 = \sum_{n=1}^N (\phi^{-1}(y_n) - \theta^T \varphi(u_n))^2 \quad \text{To już było}$$

$$\theta_N^* = \left[\sum_{n=1}^N \varphi(u_n) \varphi^T(u_n) \right]^{-1} \times \sum_{n=1}^N \phi^{-1}(y_n) \varphi(u_n)$$

lub rekurencyjnie

Algorytm rekurencyjny

$$\theta_{N+1}^* = A(\theta_N^*, u_{N+1}, y_{N+1}) = \theta_N^* + K_{N+1} [\phi^{-1}(y_{N+1}) - \phi(u_{N+1})^T \theta_N^*]$$

$$K_{N+1} = \frac{P_N \phi(u_{N+1})}{1 + \phi(u_{N+1})^T P_N \phi(u_{N+1})}$$

$$P_{N+1} = P_N - \frac{P_N \phi(u_{N+1}) \phi(u_{N+1})^T P_N}{1 + \phi(u_{N+1})^T P_N \phi(u_{N+1})}$$

Uczenie neuronu

reguła delta

$$Q(\theta) = \frac{1}{2} (y - \theta^T \varphi(u))^2, \quad \theta_0 \quad \text{Neuron adaline}$$

Numeryczna metoda optymalizacji (to będzie)

$$\theta^* \rightarrow Q(\theta^*) = \min_{\theta} Q(\theta)$$

$$\theta_{n+1}^* = \theta_n^* - \eta \nabla_{\theta} Q(\theta_n^*), \quad \theta_0^* \quad \eta - \text{współczynnik uczenia}$$

$$\nabla Q(\theta) = -(y - \theta^T \varphi(u)) \varphi(u), \quad \theta_0$$

$$\theta_{n+1}^* = \theta_n^* + \eta (y_{n+1} - \theta_n^{*T} \varphi(u_{n+1})) \varphi(u_{n+1}), \quad \theta_0^*$$

$$\Delta_n = (y_{n+1} - \theta_n^{*T} \varphi(u_{n+1}))$$

$$\theta_{n+1}^* = \theta_n^* + \eta \Delta_n \varphi(u_{n+1})$$

Uczenie neuronu

reguła delta

$$Q(\theta) = \frac{1}{2} (y - \phi(\theta^T \varphi(u)))^2, \quad \theta_0 \quad \phi - \text{funkcja aktywacji, różniczkowalna}$$

Numeryczna metoda optymalizacji (to będzie)

$$\theta^* \rightarrow Q(\theta^*) = \min_{\theta} Q(\theta)$$

$$\theta_{n+1}^* = \theta_n^* - \eta \nabla_{\theta} Q(\theta_n^*), \quad \theta_0^* \quad \eta - \text{współczynnik uczenia}$$


$$\nabla Q(\theta) = -(y - \phi(\theta^T \varphi(u))) \frac{\partial \phi(\kappa)}{\partial \kappa} \varphi(u), \quad \theta_0$$

$$\theta_{n+1}^* = \theta_n^* + \eta (y_{n+1} - \phi(\theta_n^{*T} \varphi(u_{n+1}))) \frac{\partial \phi(\kappa)}{\partial \kappa} \varphi(u_{n+1}), \quad \theta_0^*$$


$$\Delta_n = (y_{n+1} - \phi(\theta_n^{*T} \varphi(u_{n+1}))) \frac{\partial \phi(\kappa)}{\partial \kappa}$$

$$\theta_{n+1}^* = \theta_n^* + \eta \Delta_n \varphi(u_{n+1})$$

Sieć wielowarstwowa




Model neuronu (wyrwany z sieci)



$$\mu_j^{(i)} = \phi_{ij} \left(\bar{\mu}_{j-1}^T \theta_{ij} \right).$$

$$\mu_j^{(i)} = \phi_{ij} \left(\sum_{s=1}^{I_{j-1}} \mu_{j-1}^{(s)} \theta_{ij}^{(s)} + \theta_{ij}^{(0)} \right), \quad \mu_{j-1} = \begin{bmatrix} \mu_{j-1}^{(1)} \\ \mu_{j-1}^{(2)} \\ \vdots \\ \mu_{j-1}^{(I_{j-1})} \end{bmatrix}, \quad \bar{\mu}_{j-1} \stackrel{\text{df}}{=} \begin{bmatrix} \mu_{j-1}^{(0)} \\ \mu_{j-1} \end{bmatrix} = \begin{bmatrix} \mu_{j-1}^{(0)} \\ \mu_{j-1}^{(1)} \\ \mu_{j-1}^{(2)} \\ \vdots \\ \mu_{j-1}^{(I_{j-1})} \end{bmatrix}, \quad \theta_{ij} \stackrel{\text{df}}{=} \begin{bmatrix} \theta_{ij}^{(0)} \\ \theta_{ij}^{(1)} \\ \vdots \\ \theta_{ij}^{(I_{j-1})} \end{bmatrix},$$

Sieć wielowarstwowa



$$\mu_j = \begin{bmatrix} \mu_j^{(1)} \\ \mu_j^{(2)} \\ \vdots \\ \mu_j^{(I_j)} \end{bmatrix} = \begin{bmatrix} \phi_{1j}(\bar{\mu}_{j-1}^T \theta_{1j}) \\ \phi_{2j}(\bar{\mu}_{j-1}^T \theta_{2j}) \\ \vdots \\ \phi_{I_{jj}}(\bar{\mu}_{j-1}^T \theta_{I_{jj}}) \end{bmatrix} \stackrel{\text{df}}{=} \phi_j(\bar{\mu}_{j-1}, \theta_j),$$

$$\theta_j \stackrel{\text{df}}{=} \begin{bmatrix} \theta_{1j} & \theta_{2j} & \dots & \theta_{I_{jj}} \end{bmatrix} = \begin{bmatrix} \theta_{1j}^{(0)} & \theta_{2j}^{(0)} & \dots & \theta_{I_{jj}}^{(0)} \\ \theta_{1j}^{(1)} & \theta_{2j}^{(1)} & \dots & \theta_{I_{jj}}^{(1)} \\ \vdots & \vdots & \ddots & \vdots \\ \theta_{1j}^{(I_{j-1})} & \theta_{2j}^{(I_{j-1})} & \dots & \theta_{I_{jj}}^{(I_{j-1})} \end{bmatrix}.$$

$$\mu_j = \phi_j(\bar{\mu}_{j-1}, \theta_j), \quad j = 1, 2, \dots, J.$$

$$\mu_1 = \phi_1(\bar{\mu}_0, \theta_1) = \phi_1(u, \theta_1).$$

$$\mu_j = \phi_j(\bar{\mu}_{j-1}, \theta_j), \quad j = 2, 3, \dots, J-1.$$

$$\bar{y} = \mu_J = \phi_J(\bar{\mu}_{J-1}, \theta_J).$$

$$\bar{y} = \begin{bmatrix} \bar{y}^{(1)} \\ \bar{y}^{(2)} \\ \vdots \\ \bar{y}^{(L)} \end{bmatrix} = \begin{bmatrix} \mu_J^{(1)} \\ \mu_J^{(2)} \\ \vdots \\ \mu_J^{(I_J)} \end{bmatrix} = \phi_J(\phi_{J-1}(\dots \phi_1(u, \theta_1), \dots, \theta_{J-1}), \theta_J) \stackrel{\text{df}}{=} \begin{bmatrix} \Phi^{(1)}(u, \theta) \\ \Phi^{(2)}(u, \theta) \\ \vdots \\ \Phi^{(L)}(u, \theta) \end{bmatrix} \stackrel{\text{df}}{=} \Phi(u, \theta),$$

$$\theta \stackrel{\text{df}}{=} \{\theta_1, \theta_2, \dots, \theta_J\}.$$

$$Q(\theta) = \sum_{n=1}^N Q_n(\theta) = \sum_{n=1}^N [y_n - \Phi(u_n, \theta)]^T [y_n - \Phi(u_n, \theta)] = \sum_{n=1}^N \sum_{l=1}^L (y_n^{(l)} - \Phi^{(l)}(u_n, \theta))^2$$

Uczenie sieci wielowarstwowej

$$Q_n(\theta) = [y_n - \Phi(u_n, \theta)]^T [y_n - \Phi(u_n, \theta)] = \sum_{l=1}^L (y_n^{(l)} - \Phi^{(l)}(u_n, \theta))^2 = \sum_{l=1}^L \varepsilon_n^{(l)2} \quad \varepsilon_n^{(l)} \stackrel{\text{df}}{=} y_n^{(l)} - \bar{y}_n^{(l)} = y_n^{(l)} - \Phi^{(l)}(u_n, \theta), \quad l = 1, 2, \dots, L$$

$$\left. \frac{\partial Q_n(\theta)}{\partial \theta_{ij}^{(s)}} \right|_{\theta_{ij}^{(s)} = \tilde{\theta}_{ij,n}^{(s)}} = -2\delta_{jn}^{(i)} \mu_{j-1,n}^{(s)}, \quad \tilde{\theta}_{ij,n+1}^{(s)} = \tilde{\theta}_{ij,n}^{(s)} - \eta_n \left. \frac{\partial Q_n(\theta)}{\partial \theta_{ij}^{(s)}} \right|_{\theta_{ij}^{(s)} = \tilde{\theta}_{ij,n}^{(s)}}, \quad s = 0, 1, \dots, I_{J-1}, \quad i = 1, 2, \dots, I_J, \quad j = 1, 2, \dots, J,$$

$$\varepsilon_{jn}^{(i)} \stackrel{\text{df}}{=} \begin{cases} \varepsilon_n^{(i)} & \text{dla } j = J \\ \sum_{p=1}^{I_{j+1}} \delta_{j+1,n}^{(p)} \tilde{\theta}_{pj+1,n}^{(i)} & \text{dla } j = J-1, J-2, \dots, 1 \end{cases}$$

$$\delta_{jn}^{(i)} \stackrel{\text{df}}{=} \varepsilon_{jn}^{(i)} \left. \frac{d\phi_{ij}(\kappa_j^{(i)})}{d\kappa_j^{(i)}} \right|_{\theta_{ij}^{(s)} = \tilde{\theta}_{ij,n}^{(s)}}$$

$$\kappa_j^{(i)} \stackrel{\text{df}}{=} \sum_{s=1}^{I_{j-1}} \mu_{j-1}^{(s)} \theta_{ij}^{(s)} + \theta_{ij}^{(0)}.$$

$$\tilde{\theta}_{ij,n+1}^{(s)} = \tilde{\theta}_{ij,n}^{(s)} + 2\eta_n \delta_{jn}^{(i)} \mu_{j-1,n}^{(s)}, \quad s = 0, 1, \dots, I_{J-1}, \quad i = 1, 2, \dots, I_J, \quad j = 1, 2, \dots, J.$$

Optymalizacja funkcjonału


$$x^*(t) \rightarrow \mathcal{F}(x^*(t)) = \min_{x(t)} \mathcal{F}(x(t))$$

Wariacja funkcjonału:

dla $x(t) + \delta h(t)$ $\mathcal{F}(x(t) + \delta h(t))$

Warunek konieczny

$$\left. \frac{\partial \mathcal{F}(x(t) + \delta h(t))}{\partial \delta} \right|_{\delta=0} = 0, \forall h(t)$$



Optymalizacja funkcjonału przykład

$$\mathcal{F}(x(t)) = \int_{t_a}^{t_b} (x^2(t) - 2x(t)) dt$$

$$\mathcal{F}(x(t) + \delta h(t)) = \int_{t_a}^{t_b} ((x(t) + \delta h(t))^2 - 2(x(t) + \delta h(t))) dt$$

$$\left. \frac{\partial \mathcal{F}(x(t) + \delta h(t))}{\partial \delta} \right|_{\delta=0} = 0, \quad \forall h(\tau)$$

$$\left. \frac{\partial \mathcal{F}(x(t) + \delta h(t))}{\partial \delta} \right|_{\delta=0} = 2 \int_{t_a}^{t_b} (x(t) + \delta h(t) - 1) h(t) dt \Big|_{\delta=0} = 0 \quad \forall h(t)$$

$$(x(t) - 1) = 0 \quad \Rightarrow \quad x(t) = 1, \quad t \in [t_a, t_b]$$

Optymalizacja funkcjonału z ograniczeniami - przykład

$$x^*(t) \rightarrow \mathcal{F}(x^*(t)) = \min_{x(t) \in \mathcal{D}(x(t))} \mathcal{F}(x(t))$$

Przy ograniczeniach

$$\mathcal{D}(x(t)) = \{x(t); \mathcal{G}_m(x(t)) = 0, m = 1, 2, \dots, M\}$$

Funkcjonał Lagrange'a

$$\mathcal{L}(x(t), \lambda) = \mathcal{F}(x(t)) + \sum_{l=1}^L \lambda_l \mathcal{G}_l(x(t))$$

Wariacja Funkcjonału Lagrange'a

$$\mathcal{L}(x(t) + \delta h(t), \lambda) = \mathcal{F}(x(t) + \delta h(t)) + \sum_{l=1}^L \lambda_l \mathcal{G}_l(x(t) + \delta h(t))$$

Warunek konieczny

$$\left. \frac{\partial \mathcal{L}(x(t) + \delta h(t))}{\partial \delta} \right|_{\delta=0} = 0, \forall h(t)$$

Optimalizacja funkcjonału z ograniczeniami - przykład

$$\mathcal{F}(x(t)) = y(t_b) = \int_{t_a}^{t_b} k_i(t_a - t)x(t)dt$$

$$\mathcal{D}(x(t)) = \left\{ x(t), t \in [t_a, t_b]; \mathcal{G}(x(t)) = \int_{t_a}^{t_b} x^2(t)dt - E = 0, \right\}$$

$$\mathcal{L}(x(t), \lambda) = \int_{t_a}^{t_b} k_i(t_a - t)x(t)dt + \int_{t_a}^{t_b} x^2(t)dt - E$$

$$\mathcal{L}(x(t) + \delta h(t), \lambda) = \int_{t_a}^{t_b} k_i(t_a - t)(x(t) + \delta h(t))dt$$

$$+ \lambda \int_{t_a}^{t_b} (x(t) + \delta h(t))^2 dt - E$$

Optimalizacja funkcjonału z ograniczeniami - przykład


$$\left. \frac{\partial \mathcal{L}(x(t) + \delta h(t))}{\partial \delta} \right|_{\delta=0} = 2 \int_{t_a}^{t_b} (k_i(t_a - t) + 2\lambda(x(t) + \delta h(t))h(t)) dt \Big|_{\delta=0} = 0 \quad \forall h(t)$$

$$k_i(t_a - t) + 2\lambda x(t) = 0 \quad \Rightarrow \quad x(t) = -\frac{1}{2\lambda} k_i(t_a - t), \quad t \in [t_a, t_b]$$

$$\int_{t_a}^{t_b} x^2(t) dt - E = 0 - E = 0 \Rightarrow \int_{t_a}^{t_b} \left(-\frac{1}{2\lambda} k_i(t_a - t) \right)^2 dt = E$$

$$\lambda^* = \pm \frac{1}{2\sqrt{E}} \int_{t_a}^{t_b} k_i^2(t_a - t) dt, \quad x(t) = \mp \frac{\sqrt{E}}{\int_{t_a}^{t_b} k_i^2(t_a - t)} k_i(t_a - t), \quad t \in [t_a, t_b]$$

Model w badaniach systemowych



Dziękuję za uwagę

