

## O PEWNYM PROBLEMIE MAYERA STEROWANIA OPTYMALNEGO W PRZYPADKU STOCHASTYCZNYM

**Wiesław Grygierzec**

Katedra Statystyki i Ekonometrii, Uniwersytet Rolniczy w Krakowie  
e-mail: rrgrgie@cyf-kr.edu.pl

**Streszczenie:** Rozważamy problem stochastycznego sterowania optymalnego dla układu opisywanego poprzez stochastyczne równanie różniczkowe typu Ito. Układy takie bywają też nazywane jako *modele dyfuzyjne*. Źródłem niepewności w takich modelach jest *biały szum* który odzwierciedla oddziaływanie dużej ilości niezależnych sił losowych. W tej sytuacji problem sterowania polega na podejmowaniu na podstawie możliwie najnowszych informacji, odpowiednich decyzji spośród wszystkich możliwych w celu osiągnięcia zamierzonego celu. Kluczowa rolę odgrywa w tym zagadnieniu tzw. *funkcja wartości*, która w jakiś sposób charakteryzuje nam ewolucję w czasie minimalnej wartości funkcjonału kosztu. W niniejszym artykule autor udawania pewne własności funkcji wartości dla tzw. *problemu Mayera* czyli dla specjalnej postaci funkcjonału kosztu.

**Słowa kluczowe:** stochastyczne sterowanie optymalne, funkcja wartości, problem Mayera

### WSTĘP

Niniejszy artykuł jest poświęcony przedstawieniu pewnych własności funkcji wartości dla problemu stochastycznego sterowania optymalnego. Wiele zjawisk przyrodniczych pojawiających się w zastosowaniach jest modelowane za pomocą równań różniczkowych postaci

$$\frac{dx}{dt} = b(t, x(t)) + v(t) \quad (1)$$

gdzie  $x(t) \in R^n$ , tzn.  $x = (x_1(t), \dots, x_n(t))$  opisuje stan układu w chwili  $t$  natomiast  $v(t)$  reprezentuje nieznane zakłócenie. Kiedy takie zakłócenie ma nieregularny i nieprzewidywalny charakter naturalnym jest przyjęcie procesu stochastycznego w postaci:

$$v(t) = \sigma(t, x(t)) \frac{dw}{dt},$$

gdzie  $\frac{dw}{dt}$  to zapis formalny pochodnej czasowej procesu Wienera, która jak wiadomo nie istnieje w sensie klasycznym ale jako tzw. pochodna dystrybucyjna, czyli jest to tzw. biały szum. W notacji stochastycznej równanie (1) zapisujemy jako

$$dx(t) = b(t, x(t))dt + \sigma(t, x(t))dw(t).$$

Rozważamy następujący stochastyczny układ ze sterowaniem opisujący ewolucję funkcji stanu  $y(t) \in R^d$


$$\begin{cases} dy(t) = f(t, y(t), u(t))dt + \sigma(t, y(t), u(t))dW(t), & s \in (t_0, T] \\ y(t_0) = x_0 \end{cases} \quad (2)$$

gdzie  $(t_0, x_0)$  są ustalone. Zakładamy, że dana jest określona przestrzeń probabilistyczna z filtracją  $(\Omega, F, \{F_t\}_{t \geq t_0}, P)$ , na której jest zdefiniowany standardowy proces Wienera  $\Omega(\tau)$ , natomiast  $\alpha(t) = \alpha(t, \omega)$  jest sterowaniem w chwili  $\tau$  zależnym od parametru losowego  $\omega \in \Omega$ .

Założmy że spełnione są warunki gwarantujące istnienie jednoznacznego rozwiązania  $y(t) = y(t; t_0, x_0, u)$  układu (2). Problem sterowania związany jest z zadaniem zbiorem  $M \subset R^d$  oraz deterministyczną funkcją  $g(t, x)$  określona na brzegu  $\partial M$  tego zbioru, tzn.

$$g : [t_0, \infty) \times \partial M \rightarrow R \quad (3)$$

Rysunek 1. Problem Mayera



Źródło: opracowanie własne

oraz z tzw. *momentem stopu*  $t_1$ , czyli *momentem Markowa*, który zdefiniowany jest w sposób następujący. Jako zbiór sterowań dopuszczalnych przyjmujemy tylko takie sterowania  $u(t)$ , które w skończonym czasie przeprowadzają wektor stanu  $\psi(\tau)$  do zbioru  $M$  p.n., tzn. istnieje taki (losowy) moment  $t_1 = t_1(\omega)$ , *moment stopu*, że  $y(t_1) \in M$

$$t_1 = \inf\{t > t_0, y(t; t_0, x_0, u) \in M \text{ p.n.}\}. \quad (4)$$

W dalszej części naszego artykułu zasadniczą rolę będzie odgrywać tzw. *funkcja wartości*  $v$ :

$$v(t_0, x_0) = \inf_{u \in U_{t_0, x_0}} Eg(t_1, y(t_1; t_0, x_0, u)), \quad (5)$$

gdzie przez  $U_{t_0, x_0}$  oznaczamy zbiór sterowań dopuszczalnych dla warunku początkowego  $(t_0, x_0)$ . Zagadnienie sterowania optymalnego z powyżej zdefiniowaną funkcją wartości nazywamy *problemem Mayera* dla sterowania optymalnego.

W teorii sterowania optymalnego rozważa się dwa zasadnicze podejścia: Podejście Pontryagina, które opiera się o *zasadę maksimum*<sup>1</sup> oraz podejście Bellmana czyli oparte o *programowanie dynamiczne*. W tym ostatnim poszukuje się tzw. *funkcji wartości*, która ma tutaj kluczowe znaczenie i wykazanie pewnych jej własności jest właśnie przedmiotem niniejszego artykułu. Podobne zagadnienie w sytuacji deterministycznej jest przedstawione np. książce [Fleming, Rischel 1975]. Również monografie [Fleming, Soner 1993] oraz [Yong, Zhou 1999] są

<sup>1</sup> Grygierzec W. (2012) O jednolitym podejściu do rachunku wariacyjnego i sterowania optymalnego. *Metody Ilościowe w Badaniach Ekonomicznych*, XIII/1.

poświęcone problemom m.in. własności funkcji wartości. Podejście przedstawione w niniejszej pracy jest bliskie tzw. twierdzeniu weryfikacyjnemu chociaż nie całkowicie się z nim pokrywa, stanowi istotny wkład w lepsze zrozumienie i poszukiwanie rozwiązań optymalnego sterowania.

## OZNACZENIA I DEFINICJE

### Zmienna losowa, proces stochastyczny

Przypomnijmy, dla użytku czytelnika podstawowe definicje i właściwości dotyczące procesów stochastycznych z których będziemy korzystali w dalszej części. Niech  $\Omega$  będzie niepustym zbiorem,  $F$   $\sigma$ -algebrą jego podzbiorów;  $\Pi$  miara probabilistyczna na  $\Omega$  ( $P: F \rightarrow [0,1]$ ). Trójkę  $(\Omega, F, P)$  standardowo nazywamy *przestrzenią probabilistyczną*. Funkcję  $x: \Omega \rightarrow R^d$ , mierzalną względem  $F$  nazywamy *zmienną losową* o wartościach w  $R^d$ .

Oznaczmy przez  $I = [0, T], T \leq \infty$  przedział domknięty w  $R$ . *Procesem stochastycznym*  $x$  nazwiemy rodzinę zmiennych losowych  $\{x(t)\}_{t \in I}$  czasami oznaczanych jako  $x_t$ . Formalnie zatem proces stochastyczny to funkcja dwóch zmiennych:

$$x: I \times \Omega \rightarrow R^d,$$

mierzalna względem drugiej zmiennej dla dowolnego  $t \in I$ . Przy ustalonym  $\omega \in \Omega$ , funkcję  $t \rightarrow x(t, \omega)$  nazwiemy trajektorią procesu  $x_t$ . Proces stochastyczny nazywamy ciągłym jeżeli  $x(\cdot, \omega)$  jest ciągły jako funkcja  $t$ , dla prawie wszystkich  $\omega \in \Omega$ . Rodzinę  $\{F_t\}_{t \in I}$   $\sigma$ -algebr nazywamy *filtracją* jeżeli dla  $s \leq t, s, t \in I$  zachodzi:

$$F_s \subset F_t \subset F.$$

Układ  $(\Omega, F, \{F_t\}_{t \in I}, P)$  nazywamy *przestrzenią probabilistyczną z filtracją*. Proces stochastyczny  $x_t$  nazywamy  *$F_t$ -adaptowanym* jeżeli dla dowolnego  $t \in I$ ,  $\omega \rightarrow x_t(\omega)$  jest  $F_t$ -mierzalna. Niech będzie dany dowolny proces stochastyczny  $x_t$  oraz niech  $F_t$  będzie najmniejszą  $\sigma$ -algebrą generowaną przez  $x_s; s \leq t$ , wówczas  $x_t$  jest adaptowany do  $F_t$ ; Dla  $t \in I$ , oznaczamy  $F_t^x = \sigma(x_s : s \leq t)$ , najmniejszą  $\sigma$ -algebrę względem której  $x_s$  jest mierzalny dla  $s \leq t$ . Jest ona nazywana  $\sigma$ -algebrą generowaną przez  $x$  do chwili  $t$ , zatem można ją uważać za "historie" zmiennej losowej  $x_t$ .

### Warunkowa wartość oczekiwana, Martyngały

Własności wartości oczekiwanej dla trajektorii optymalnej są przedmiotem niniejszego artykułu, przypomnijmy w związku z tym dla wygody czytelnika

najważniejsze definicje. *Warunkowa wartość oczekiwana* zmiennej losowej  $x$  pod warunkiem zdarzenia  $A$  zdefiniowana jest jako:

$$E(x|A) = \frac{1}{P(A)} \int_A x(\omega) dP.$$

*Warunkową wartość oczekiwaną* zmiennej losowej  $x$  pod warunkiem  $\sigma$ -ciała  $G \subset F$  nazywamy zmienną losową  $E(x|G)$  spełniającą warunki:

- (1)  $E(x|G)$  jest  $G$ -mierzalna
- (2) dla dowolnego  $A \in G$  zachodzi

$$\int_A E(x|G)(\omega) dP(\omega) = \int_A x(\omega) dP(\omega).$$

Adaptowany proces stochastyczny  $x_t, t \in I$  nazywamy *martyngałem* (*podmartyngałem, nadmartyngałem*) względem filtracji  $F_t$  jeżeli:

- (1)  $x_t$  całkowalny dla dowolnego  $t \in I$ ,
- (2)  $x_s = E(x_t | F_s)$  p.n. (odp.  $\leq, \geq$ ) dla dowolnego  $s, t \in I, s \leq t$ .

### Proces Wienera, Całka stochastyczna Ito

Niech dana będzie przestrzeń probabilistyczna z filtracją  $(\Omega, F, \{F_t\}_{t \in I}, F, P)$  proces stochastyczny  $w_t = (w_1, \dots, w_d)$  nazwiemy *procesem ruchu Browna* albo *procesem Wienera* w  $R^d$  jeżeli jest ciągłym procesem Gaussowskim o niezależnych przyrostach, tzn.

- (1)  $w_0 = 0$  p.n. (prawie na pewno)
- (2) dla dowolnego  $0 \leq s < t$  zmienna losowa  $w_t - w_s$  jest niezależna od  $F_s$ ,
- (3) przyrosty  $w_t - w_s$  mają rozkład normalny, tzn.  $N(0, (t-s)I_d)$ , gdzie  $I_d$  jest macierzą jednostkową w  $R^d$ .

Jeżeli filtracja  $\{F_t\}$  nie jest zadana w sposób jawny, możemy uważać, że jest to właśnie filtracja  $\{F_t^w\}$ , czyli generowana przez proces Wienera  $w_t$  i wówczas warunek (2) odpowiada warunkowi:

- (2') proces  $w_t$  posiada niezależne przyrosty tzn. dla  $t < s < r < u$ ,  $(w_t - w_s)$  oraz  $(w_u - w_r)$  są niezależne.

Można pokazać, że gęstość prawdopodobieństwa  $w_t$  wyraża się wzorem:

$$p(t, x) = (2\pi)^{-d/2} \exp\left\{-|x|^2 / (2t)\right\}$$

Przypomnijmy dla wygody czytelnika definicje całki stochastycznej Ito. Przedstawiamy jedynie zasadniczą ideę natomiast osoby zainteresowane bardziej szczegółowym opisem zachęcamy do sięgnięcia do standardowych pozycji książkowych takich jak [Ikeda, Watanabe 1989] czy [Kartzas, Shreve 1991].

Konstrukcje całki stochastycznej Ito  $I(f)_t = \int_0^t f_s dW_s$  rozpoczniemy od zdefiniowania zbioru funkcji dla których jest ona poprawnie określona. Dla  $T > 0$  przez  $L^2_F(0, T; R)$  oznaczamy zbiór wszystkich mierzalnych procesów  $\phi(\tau; !)$  adaptowanych do filtracji  $\{F_t\}_{t \geq 0}$  o skończonej normie

$$\|f\|_T^2 = E \left\{ \int_0^T f(t, \omega) dt \right\} < \infty.$$

Krok I. Definiujemy całkę najpierw dla procesów schodkowych postaci:

$$f_t(\omega) = \sum_{i=0}^{n-1} \xi_i(\omega) \chi_{[t_i, t_{i+1})}(t),$$

dla danego podziału:  $0 = t_0 < t_1 < \dots < t_n = T$ , przedziału  $[0, T]$  gdzie  $\xi_i$  jest  $F_{t_i}$  mierzalna,  $E(\xi_i^2) < \infty$ , natomiast  $\chi_{[t_i, t_{i+1})}(t)$  jest funkcją charakterystyczną odcinka  $[t_i, t_{i+1})$ . Całka stochastyczna procesu schodkowego jest zdefiniowana jako

$$\int_0^t f_s dW_s = \sum_i \xi_i(\omega) (W_{t_{i+1} \wedge t}(\omega) - W_{t_i \wedge t}(\omega)).$$

Dowodzi się prawdziwość tożsamości izometrycznej:

$$E \left( \left| \int_0^t f_s dW_s \right|^2 \right) = E \int_0^t |f_s|^2 ds,$$

oraz nierówności Barkholdera-Davisa-Gundy:

$$E \sup_{0 \leq t \leq T} \left| \int_0^t f_s dW_s \right|^p \leq c_p E \left( \int_0^T |f_s|^2 ds \right)^{p/2},$$

gdzie  $c_p$  jest stałą zależną od  $T > 0$  oraz  $p > 0$ .

Krok II. Rozszerzamy definicję poprzez przejście graniczne na adaptowane procesy stochastyczne spełniające:

$$E \int_0^T |x_s(\omega)|^2 ds < \infty. \quad (6)$$

Krok III. Kolejne rozszerzenie definicji całki poprzez tzw. lokalizacje na klasę wszystkich adaptowanych procesów spełniających

$$P \left\{ \int_0^T |x_s(\omega)|^2 ds < \infty \right\} = 1. \quad (7)$$

Całka stochastyczna Ito jest poprawnie zdefiniowana jeżeli zachodzi warunek (7), jeżeli zachodzi silniejszy warunek (6) wówczas jest ona martyngałem.

## PROBLEM STEROWANIA OPTYMALNEGO MAYERA

### Stochastyczny układ ze sterowaniem

Problem sterowania będzie polegał na minimalizacji wartości oczekiwanej pewnego funkcjonału *funkcji stanu* oraz *procesu sterowania*. Funkcja stanu to proces stochastyczny  $y(t) \in R^d$ , o wartościach w  $R^d$  opisywany przez następujące stochastyczne równanie różniczkowe typu Ito:

$$dy(t) = f(t, y(t), u(t))dt + \sigma(t, y(t), u(t))dW(t), s \in [t_0, T],$$

które będziemy rozumieli jako równanie całkowe

$$y(t) = y(t_0) + \int_{t_0}^t f(t, y(t), u(t))dt + \int_{t_0}^t \sigma(t, y(t), u(t))dW_t \quad (8)$$

gdzie  $u(t) \in U$  jest parametrem czyli sterowaniem zastosowanym w chwili  $t$  przyjmującym wartości z pewnego zbioru  $U \subset R^n$ , ograniczonego oraz domkniętego. Oznaczmy przez  $Q = [0, T] \times R^d$ .

Przyjmujemy następujące założenia: niech funkcje

$$f : Q \times U \rightarrow R^d,$$

$$\sigma : Q \times U \rightarrow R^d \times R^d,$$

będą ciągłe oraz niech  $f(\cdot, \cdot, v)$ ,  $\sigma(\cdot, \cdot, v)$  będą klasy  $C^1(Q)$ . Zakładamy, że istnieje pewna stała  $C > 0$ , taka, że:

$$(1) |f_t| + |f_x| + |\sigma_t| + |\sigma_x| \leq C,$$

$$(2) |f(t, x, v)| + |\sigma(t, x, v)| \leq C(1 + |x| + |v|),$$

gdzie  $f_t, f_x$  oznaczają odpowiednie pochodne cząstkowe  $\frac{\partial f}{\partial t}$  oraz  $\frac{\partial f}{\partial x}$ ,  $|\sigma|$  jest normą operatorową  $\sigma$  również  $\sigma_t, \sigma_x$  są pochodnymi cząstkowymi funkcji  $\sigma$  o wartościach macierzowych.

Z ogólnej teorii stochastycznych równań różniczkowych wiadomo, że przy powyższych założeniach równanie (8) ma dokładnie jedno rozwiązanie  $y(t) \in L^2(\Omega; C(0, T; R^d))$ , gdzie

$$L^2(\Omega; C(0, T; R^d)) = \{x_t : E \sup_{t \in [0, T]} |x_t|^2 < \infty\}.$$

**Kryterium do minimalizacji - Problem Mayera**

Rozważamy rodzinę stochastycznych problemów Cauchy'ego indeksowana po  $(s, x) \in [0, T] \times R^d$ :

$$\begin{cases} dy(t) = f(t, y(t), u(t))dt + \sigma(t, y(t), u(t))dW(t), t \in (s, T] \\ y(s) = x, (s, x) \text{ dowolne} \end{cases} \quad (9)$$

oraz funkcję (3)  $g(t, x) \in C^1([0, \infty) \times \partial M; R)$ , niech  $y(t; s, x, u)$  będzie trajekcją rozwiązania (9) oraz  $t_1$  będzie momentem zatrzymania (4). Zbiór sterowań dopuszczalnych

$$U_{s,x} = \{u : [0, \infty) \times \Omega \rightarrow U \mid F_t \text{ - adaptowane, } t_1(s, x, u(\cdot)) < \infty \text{ p.n.}\} \quad (10)$$

Powiemy, że  $y^*$  jest trajekcją optymalną a  $(y^*, u^*)$  parą optymalną jeżeli

$$v(t_0, x_0) = \inf_{u \in U_{t_0, x_0}} Eg(t_1, y(t_1; t_0, x_0, u)) = Eg(t_1, y^*(t_1; t_0, x_0, u^*)). \quad (11)$$

**WŁASNOŚCI FUNKCJI WARTOŚCI**

Przy powyższych założeniach prawdziwe są następujące twierdzenia.

**Twierdzenie 1**

*Proces  $v(t, y(t))$  jest podmartyngalem dla  $t \in [t_0, t_1]$  tzn.*

$$v(s, y(s)) \leq E[v(t, y(t)) \mid F_s] \text{ p.n.}$$

dla  $t_0 \leq s \leq t \leq t_1$ .

*Dowód.* Zauważmy najpierw, że z definicji (5) funkcji wartości wynika

$$\begin{aligned} v(s, y(s)) &= \text{ess inf}_{u \in U_{s, y(s)}} E[g(t_1, y(t_1, s, y(s), u)) \mid F_s] \\ v(t, y(t)) &= \text{ess inf}_{u \in U_{t, y(t)}} E[g(t_1, y(t_1, t, y(t), u)) \mid F_t] \end{aligned} \quad (12)$$

oraz, że

$$v(s, y(s)) = E[v(s, y(s)) \mid F_s] = E[v(s, y(s)) \mid F_t]$$

Ustalmy dowolne  $u \in U_{t_0, x_0}$ , wówczas dla dowolnego  $t > s > t_0$  z jednoznaczności rozwiązania  $y(t)$  po Ścieszkach dla potoku  $y(t)$  rozwiązania SDE wynika własność Markowa czyli

$$y(t; t_0, x_0, u) = y(t; s, y(s; t_0, x_0, u), u) \text{ dla dowolnego } s \geq t_0$$

z powyższego mamy

$$v(s, y(s, u)) = E[v(s, y(s, u)) \mid F_t] \leq E[g(t_1, y(t_1, u)) \mid F_t]$$

biorąc essinf

$$v(s, y(s, u)) \leq \text{ess inf}_{u \in U_{t, y(t)}} E[g(t_1, y(t_1, t, y(t), u)) \mid F_t] = v(t, y(t, u))$$

na koniec bierzemy obustronnie  $E[\cdot \mid F_s]$ .



### Twierdzenie 2

$y^*$  - trajektoria optymalna  $\Rightarrow v(t, y(t)) \equiv \text{const p.w.}$

*Dowód.* Z definicji trajektorii optymalnej (11)

$$v(t_0, x_0) = Eg(t_1, y^*(t_1)),$$

natomiast z Twierdzenia 1 mamy

$$\begin{aligned} Eg(t_1, y^*(t_1)) &= v(t_0, x_0) \leq E[v(t, y^*(t)) | F_{t_0}] = Ev(t, y^*(t)) = \\ &= E \left[ \underset{u \in U_{t, y^*(t)}}{\text{ess inf}} E[g(t_1, y^*(t_1)) | F_t] \right] \leq Eg(t_1, y^*(t_1)) \end{aligned}$$

Ponieważ na początku i na końcu ciągu nierówności mamy to samo wyrażenie zatem nierówności w środku można zamienić na równości.

### WNIOSEK

*Funkcja wartości* jest na wszystkich trajektoriach rozwiązania układu (2) jest podmartyngałem, jedynie na *trajektorii optymalnej* jest stała prawie wszędzie względem miary probabilistycznej  $P$  i to jest najprostsze kryterium aby rozpoznać *parę optymalną* czyli *sterowanie optymalne* oraz *trajektorię optymalną*.

### BIBLIOGRAFIA

- Fleming W. H., Rishel R. W. (1975) Deterministic and Stochastic Optimal Control. Springer-Verlag.
- Fleming W. H., Soner H. M. (1993) Controlled Markov Processes and Viscosity Solutions. Springer-Verlag.
- Hausmann U. G. (1986) A Stochastic Maximum Principle for Optimal Control of Diffusions. Pitman Research Notes in Mathematics, 151, Longman.
- Grygierzec W. (2012) O jednolitym podejściu do rachunku wariacyjnego i sterowania optymalnego. Metody Ilościowe w Badaniach Ekonomicznych, XIII/1.
- Kartzas I., Shreve S. E. (1991) Brownian Motion and Stochastic Calculus. (Graduate Texts in Mathematics), Springer-Verlag.
- Ikeda, N., Watanabe S. (1989) Stochastic Differential Equations and Diffusion Processes. 2nd Edition, North Holland-Kodansha, Amsterdam-Tokyo, 1989.
- Peng S. (1990) A general stochastic maximum principle for optimal control problems. SIAM Journal on Control and Optimization, 28 (4), 966-979.
- Pham H. (2009) Continuous-time Stochastic Control and Optimization with Financial Applications. Springer-Verlag.
- Szafirski B. (2012) Notes from seminar, not published.
- Yong J., Zhou X. Y. (1999) Stochastic Controls, Hamiltonian Systems and HJB Equations. Springer-Verlag.

**ABOUT SOME MAYER STOCHASTIC OPTIMAL CONTROL  
PROBLEM**

**Abstract:** We consider optimal control problem of system which is covered by Ito's stochastic differential equation. Such systems are sometimes called *diffusion models*. The basic source of uncertainty in such models is white noise, which represents large numbers of independent random forces. The controller has to make relevant decision, based on the most update information among all the possible to achieve the best expected result relevant his goal. The key role play so called *value function* which represent in some sense evolution of minimal cost functional in time. In the present paper the author give some characterization of value function for the so called *Mayer problem* which correspond to special form of cost.

**Keywords:** stochastic optimal control, value function, Mayer problem