

Autoreferat

Michał D. Lemańczyk

2020/12/29

1 Abstrakt

Niech $\mathbf{X} = (X_i)_{i \in \mathbb{Z}}$, gdzie $X_i \in \mathcal{X}$ a \mathcal{X} jest (mierzalną) przestrzenią stanów, będzie procesem stochastycznym. Niniejsza rozprawa doktorska koncentruje się na **procesach czasów powrotu** $\mathbf{R} = (R_i)_{i \in \mathbb{Z}}$ kolejnych powrotów X_i do A oraz ich roli zarówno w teorii prawdopodobieństwa, jak i w teorii ergodycznej. Przypomnijmy, że dla danego podzbioru $A \subset \mathcal{X}$ odpowiadający mu proces czasów powrotu jest zdefiniowany jako

$$R_i = \begin{cases} \inf\{j \geq 0 : X_j \in A\}, & i = 0, \\ \inf\{j > R_{i-1} : X_j \in A\}, & i \geq 1, \\ \sup\{j < R_{i+1} : X_j \in A\}, & i \leq -1. \end{cases} \quad (1.1)$$

Głównym rezultatem rozprawy w teorii prawdopodobieństwa jest dowód nierówności Bernsteina dla funkcjonałów addytywnych ogólnych, **niekoniecznie** silnie aperiodycznych, łańcuchów Markowa, co daje odpowiedź na pytanie sformułowane w pracy [3] (patrz [A3]). Dowodzimy również pewnej nowej wersji nierówności Bernsteina dla 1-zależnych procesów (klasa ta jest silnie związana z łańcuchami Markowa dzięki tzw. technice regeneracji). Główne rezultaty w teorii ergodycznej dotyczą dokładnych wzorów, bądź nierówności, związanych z entropią (ang. entropy rate) punktowego iloczynu procesów (patrz [A1]). Stają się one narzędziem do rozwiązania kilku otwartych problemów. Podajemy nowy, jawny wzór na ciśnienie topologiczne układów \mathcal{B} -wolnych oraz, w pewnych przypadkach, dowodzimy jedyności stanów równowagi dla układu wyznaczonego przez \mathcal{B} (co rozszerza rezultaty o wewnętrznej ergodyczności udowodnione w [46, 33]). Odpowiadamy na pytanie postawione w [46] o braku własności Gibbsa dla miary o maksymalnej entropii (patrz [A2]). W końcu, odpowiadamy na kilka pytań dotyczących entropii układów \mathcal{B} -wolnych z pracy [33] (patrz [A1]).

Część rezultatów rozprawy jest nowa, pozostałe rezultaty pochodzą z następujących trzech artykułów:

- [A1] J. Kułaga-Przymus and M.D. Lemańczyk. Entropy rate of product of independent processes. *Preprint: arXiv:2004.07648*, 2020.
- [A2] J. Kułaga-Przymus and M.D. Lemańczyk. Hereditary subshifts whose measure of maximal entropy has no Gibbs property. *Ukaże się w Colloquium Mathematicum, arXiv:2004.07643*, 2020.
- [A3] M.D. Lemańczyk. General Bernstein-like inequality for additive functionals of Markov chains. *Journal of Theoretical Probability*, 2020.

2 Definicje i oznaczenia

Dla uproszczenia rozważań przyjmujemy, że wszystkie zmienne losowe są zdefiniowane na wspólnej przestrzeni probabilistycznej $(\Omega, \mathcal{F}, \mathbb{P})$, przy czym przez **zmienną losową** X rozumiemy dowolną funkcję mierzalną, przyjmującą wartości w mierzalnej **przestrzeni stanów** \mathcal{X} (w skrócie $X \in \mathcal{X}$). (**Dyskretnym**) **procesem (stochastycznym)** $\mathbf{X} = (X_i)_{i \in T}$ (T jest zawsze równe albo \mathbb{N} , albo \mathbb{Z}) nazywamy rodzinę zmiennych losowych X_i przyjmujących wartości we **wspólnej** przestrzeni stanów \mathcal{X} .

Czasami zastępujemy (domyślną) miarę probabilistyczną \mathbb{P} przez jej wersję warunkową $\mathbb{P}_A(\cdot) = \mathbb{P}(\cdot \cap A) / \mathbb{P}(A)$, gdzie $A \in \mathcal{F}$, przy czym $\mathbb{P}(A) > 0$. W szczególności \mathbb{E}_A oznacza średnią warunkową liczoną względem \mathbb{P}_A .

Dla danego ciągu $\mathbf{x} \in \mathcal{X} \subset \mathcal{X}^{\mathbb{Z}}$ lub procesu $\mathbf{X} = (X_i)_{i \in \mathbb{Z}}$ oraz skończonego zbioru indeksów $N \subset \mathbb{Z}$, gdzie $N = \{i_1, \dots, i_k\}$, $i_1 < i_2 < \dots < i_k$, określamy

$$x_N = (x_{i_1}, \dots, x_{i_n}), \quad X_N = (X_{i_1}, \dots, X_{i_n})$$

(z oczywistymi modyfikacjami, gdy zbiór N jest nieskończony). Ponadto, dla dowolnych $k, l \in \mathbb{Z}$, wprowadzamy **przedziały całkowitoliczbowe** $[k, l] = \{k, k+1, \dots, l\}$, $(-\infty, k] = \{\dots, k-2, k-1, k\}$, $[l, \infty) = \{l, l+1, l+2, \dots\}$, przy czym $[k, l] = \emptyset$, o ile $k > l$. Zatem, dla przykładu, $X_{[1, n]} = (X_1, \dots, X_n)$.

Wszystkie standardowe operacje wykonywane w zbiorze liczb rzeczywistych \mathbb{R} rozszerzamy „po współrzędnych” na ciągi i procesy. Dla przykładu $\mathbf{x} + \mathbf{y} = \mathbf{w}$, gdzie $w_i = x_i + y_i$, $\mathbf{X} \cdot \mathbf{Y} = (X_i Y_i)_{i \in T}$ lub $\mathbf{X} \leq \mathbf{Y}$, gdy $X_i \leq Y_i$ p.w. dla wszystkich $i \in T$.

Niech \mathcal{X} będzie przestrzenią topologiczną (gdy \mathcal{X} jest przestrzenią co najwyżej przeliczalną, to rozpatrujemy ją z topologią dyskretną). Przypomnijmy, że odwzorowanie $S: \mathcal{X}^{\mathbb{Z}} \rightarrow \mathcal{X}^{\mathbb{Z}}$ dane przez

$$S(x_i)_{i \in \mathbb{Z}} = (x_{i+1})_{i \in \mathbb{Z}}$$

nazywamy lewostronnym **przesunięciem** lub (częściej) **shiftem**. Parę (\mathcal{X}, S) (lub krócej \mathcal{X}) nazywamy **podshiftem**, gdy $\mathcal{X} \subset \mathcal{X}^{\mathbb{Z}}$ jest domknięty i S -niezmienniczy ($S\mathcal{X} \subset \mathcal{X}$). Zauważmy, że shift S jest ciągły. Ponadto, działa on na funkcjach poprzez składanie, $Sf = f \circ S$, oraz na miarach probabilistycznych poprzez branie obrazu miary, $S\mu(\mathbf{A}) = \mu(S^{-1}\mathbf{A})$. Ponadto, jeśli $\mathbf{X} = (X_i)_{i \in \mathbb{Z}}$ jest procesem, to $S\mathbf{X} = (X_{i+1})_{i \in T}$ (czasami nazywamy $S\mathbf{X}$ **procesem przesuniętym**). Przypomnijmy, że proces \mathbf{X} nazywamy **stacjonarnym**, gdy $\mathbf{X} \sim S\mathbf{X}$ (większość procesów, które będziemy rozpatrywać w kontekście dynamicznym, będzie stacjonarna). Proces \mathbf{X} nazywamy **ergodycznym**, gdy dla dowolnej funkcji $f \in L_1(\mathbb{P})$ zachodzi wersja **mocnego prawa wielkich liczb**, a mianowicie

$$\frac{1}{n} \sum_{i=0}^{n-1} f(S^i \mathbf{X}) \xrightarrow[L_1(\mathbb{P})]{\mathbb{P} \text{ a.s.}} \mathbb{E}f(\mathbf{X}).$$

Proces \mathbf{Y} nazywamy **faktorem** procesu \mathbf{X} , jeśli istnieje funkcja (mierzalna) $g: \mathcal{X}^T \rightarrow \mathcal{Y}$ taka, że

$$Y_n = S^n g(\mathbf{X}) = g(S^n \mathbf{X}), \quad n \in \mathbb{Z}. \quad (2.1)$$

Jeśli g jest bi-mierzalną bijekcją, to mówimy, że \mathbf{X} i \mathbf{Y} są **izomorficzne**. Podkreślmy, że powyższe (trochę niestandardowe) definicje (ergodyczność, faktor, izomorfizm) są zgodne z odpowiednimi definicjami w układach dynamicznych. W końcu, dla danego podshiftu \mathcal{X} , przez $\mathcal{M}_{\mathcal{X}}$ oznaczamy **zbiór (rozkładów) wszystkich procesów stacjonarnych \mathbf{X}** takich, że $\mathbb{P}(\mathbf{X} \in \mathcal{X}) = 1$. Ponadto $\mathcal{M}_{\mathcal{X}}^e \subset \mathcal{M}_{\mathcal{X}}$ oznacza **podzbiór procesów ergodycznych**.

3 Nierówności koncentracyjne

Nierówności koncentracyjne odgrywają ważną rolę w wielu dziedzinach. Dla przykładu wymienimy tylko statystykę (estymacja kowariancji, grupowanie (ang. clustering), grafy losowe, detekcję społecznościową, uzupełnianie macierzy i wiele innych) oraz dział algorytmów losowych (np. lemat Johnsona-Lindenstraussa, cięcia maksymalne dla grafów itd.). Jako świetne źródło zarówno ścisłej teorii, ale też intuicji i zastosowań polecamy książkę Vershynina (patrz [55]). Wyjaśnimy teraz podstawowe idee.

Ustalmy zmienną losową $X \in \mathbb{R}^d$ dla pewnego $d \in \mathbb{N}$ oraz zbiór $A \subset \mathbb{R}^d$ taki, że $\mathbb{P}(X \in A) \geq 1/2$. Dla danego $t \in \mathbb{R}_+$, niech $A_t = \{x \in \mathbb{R}^d \mid |A - x| \leq t\}$ będzie t -otoczką A , a $A_t^c = \mathbb{R}^d \setminus A_t$ jej dopełnieniem. Pytamy teraz jak, szybko X koncentruje się wokół zbiorów o mierze $1/2$ lub, innymi słowy, jaki jest optymalny wybór funkcji $\alpha: \mathbb{R} \rightarrow \mathbb{R}_+$ takiej, że $\alpha(t) \xrightarrow{t \rightarrow \infty} 0$ oraz

$$\mathbb{P}(X \in A_t^c) \leq \alpha(t) \text{ zachodzi } \mathbf{jednostajnie} \text{ względem wyboru } A. \quad (3.1)$$

Rozważmy dla przykładu $X \in \mathbb{R}^d$ jednostajnie rozłożoną na sferze jednostkowej $S = \{x \in \mathbb{R}^d \mid |x| = 1\}$. Okazuje się, że w tym przypadku możemy wziąć $\alpha(t) = \exp(-\frac{d-1}{2}t^2)$. Oznacza to, że jeśli wybierzemy

dowolny zbiór $A \subset S$ taki, że $\mathbb{P}(X \in A) \geq 1/2$ (np. „czapczkę”), to prawdopodobieństwo tego, że zaobserwujemy X w odległości $\sqrt{-\frac{2}{d-1} \ln c}$ od A jest co najmniej równe c . Innymi słowy możemy przewidzieć, gdzie pojawi się X !

Jednowymiarowym odpowiednikiem (3.1) jest znalezienie optymalnej funkcji $\alpha(t)$ spełniającej

$$\mathbb{P}(|X - \mathbb{E}X| \geq t) \leq \alpha(t). \quad (3.2)$$

Ta nierówność oddaje naszą intuicję, że rzeczywiste zmienne losowe koncentrują się wokół ich średniej. Ponadto im szybciej $\alpha(t)$ maleje, tym lepiej $\mathbb{E}X$ aproksymuje X . Jeśli dla przykładu $\alpha(t) \sim \frac{1}{t^2}$, to z (relatywnie) dużym prawdopodobieństwem X może się mocno odchyłać od swojej średniej. Jednakże jeśli $\alpha(t)$ maleje ekstremalnie szybko (np. wykładniczo, tzn. $\alpha(t) \sim c^{-t^a}$ dla pewnych $a \in \mathbb{R}_+$ oraz $c > 1$), to możemy oczekiwać, że dla danej niezależnej próbki z X, X_1, X_2, \dots, X_n , z dużym prawdopodobieństwem, większość z X_i będzie się pojawiać blisko $\mathbb{E}X$.

Uwaga 3.1. Zauważmy, że dzięki nierówności Markowa można zawsze wziąć $\alpha(t) = \text{Var}(X)/t^2$ w (3.2). W szczególności, jeśli t ma rząd *standardowego odchylenia* dla przykładu $t = \sqrt{2\text{Var}(X)}$, to $\mathbb{P}(|X - \mathbb{E}X| \geq t) \leq 1/2$, lub równoważnie, $\mathbb{P}(|X - \mathbb{E}X| < t) \geq 1/2$. Po pierwsze, ta obserwacja daje natychmiast naturalny, konstruktywny przykład zbioru A z (3.1). Po drugie, nieco nieformalnie możemy powiedzieć, że standardowe odchylenie $\sqrt{\text{Var}(X)}$ jest dobrą jednostką mierzenia koncentracji miary. Dla przykładu praktyczna zasada w statystyce (ang. rule of thumb) mówi, że niemal cała masa zmiennej losowej o rozkładzie normalnym jest w odległości 2-3 takich „jednostek” od jej średniej.

Nas interesuje wersja (3.2) (zwana nierównością Bernsteina), w której zarówno $\alpha(t)$ jak i X mają specjalną postać. Przypomnijmy najpierw strukturę takiej nierówności w najprostszym przypadku, w którym zmienne są ograniczone oraz i.i.d.

Twierdzenie 3.2 (Klasyczna nierówność Bernsteina). *Jeśli $(\xi_i)_i$ jest ciągiem i.i.d. rzeczywistych, scentrowanych zmiennych losowych takim, że $\|\xi_i\|_\infty \leq M$, to dla $\sigma^2 = \mathbb{E}\xi_i^2$ oraz dowolnego $t > 0$,*

$$\mathbb{P}\left(\left|\sum_{i=1}^n \xi_i\right| \geq t\right) \leq 2 \exp\left(-\frac{t^2}{2n\sigma^2 + \frac{2}{3}Mt}\right). \quad (3.3)$$

Przeanalizujmy teraz (nieco nieformalnie) prawą stronę w (3.3). Zauważmy, że jako funkcja argumentu t prezentuje ona dwa typy zachowań: dla **„małych”** t dominuje *zachowanie gaussowskie* (rzędu $\exp(-ct^2)$ dla pewnego $c > 0$), a mianowicie,

$$2 \exp\left(-\frac{t^2}{2n\sigma^2}\right). \quad (3.4)$$

Z kolei dla **„dużych”** t *zachowanie wykładnicze* (rzędu $\exp(-ct)$ dla pewnego $c > 0$) zaczyna odgrywać główną rolę, a konkretnie część $2 \exp\left(-\frac{t}{\frac{2}{3}M}\right)$. Przez „duże” i „małe” t rozumiemy zakres tych t , dla których jeden z wyrazów, $2n\sigma^2$ lub $\frac{2}{3}Mt$, „mocno” dominuje nad drugim (w takim przypadku będziemy pisać trochę nieformalnie, że odpowiednio $2n\sigma^2 \ll \frac{2}{3}Mt$ lub $2n\sigma^2 \gg \frac{2}{3}Mt$).

„Część (3.4)” nierówności (3.3) jest zwykle nazywana *częścią gaussowską nierówności Bernsteina*. Wyjaśnijmy teraz pochodzenie tej nazwy. Załóżmy, że η_i są niezależnymi zmiennymi losowymi gaussowskimi o zerowej średniej i wariancji σ^2 , tzn. $\eta_i \sim \mathcal{N}(0, \sigma^2)$. Wiadomym jest, że zachodzą zależności

$$\sum_{i=1}^n \eta_i \sim \mathcal{N}(0, n\sigma^2) \quad \text{oraz} \quad \mathbb{P}\left(\left|\sum_{i=1}^n \eta_i\right| \geq t\right) \approx 2 \exp\left(-\frac{t^2}{2n\sigma^2}\right).$$

Zatem jeśli $2n\sigma^2 \gg \frac{2}{3}Mt$, to twierdzenie 3.2 po prostu mówi, że najgorszy przypadek (jeśli chodzi o część gaussowską) powstaje, gdy $\xi_i = \eta_i$, innymi słowy,

$$\mathbb{P}\left(\left|\sum_{i=1}^n \xi_i\right| \geq t\right) \lesssim \mathbb{P}\left(\left|\sum_{i=1}^n \eta_i\right| \geq t\right). \quad (3.5)$$

Teraz omówimy problem optymalności w (3.3). Z centralnego twierdzenia granicznego (CTG),

$$\frac{1}{\sqrt{n}} \sum_{i=1}^n \xi_i \Rightarrow \mathcal{N}(0, \sigma^2),$$

co z grubsza można przepisać jako

$$\sum_{i=1}^n \xi_i \sim \mathcal{N}(0, n\sigma^2).$$

Ta obserwacja połączona z (3.5) pokazuje, że nierówność Bernsteina (3.3) jest w istocie rzeczy (asymptotycznie) optymalną nierównością koncentracyjną (przynajmniej, gdy mowa o części gaussowskiej). Do tego faktu będziemy odnosić się, mówiąc (nieco nieprecyzyjnie), że **nierówność Bernsteina jest optymalna**.

Opuśćmy teraz świat niezależnych zmiennych losowych. Załóżmy, że $\mathbf{X} = (X_i)_{i \in \mathbb{N}}$ jest dowolnym rzeczywistym procesem takim, że $\sup_i \|X_i\|_\infty < \infty$, $\mathbb{E}X_i = 0$, dla którego chcemy udowodnić nierówność typu Bernsteina. Załóżmy dodatkowo, że CTG zachodzi dla \mathbf{X} , tzn.

$$\frac{1}{\sqrt{n}} \sum_{i=1}^n X_i \Rightarrow \mathcal{N}(0, \sigma_\infty^2) \quad \text{dla pewnej liczby } \sigma_\infty^2 \geq 0 \quad (3.6)$$

(σ_∞^2 jest nazywana **wariancją asymptotyczną**). Naturalnym jest oczekiwanie, że (np. dla procesów silnie mieszających) σ_∞^2 można policzyć jako

$$\sigma_\infty^2 = \lim_{n \rightarrow \infty} \text{Var} \left(\frac{1}{\sqrt{n}} \sum_{i=1}^n X_i \right) = \lim_{n \rightarrow \infty} \frac{1}{n} \text{Var} \left(\sum_{i=1}^n X_i \right) \quad (3.7)$$

i następujący analog nierówności (3.3) powinien zachodzić dla odpowiedniego wyboru stałej $C \geq 0$:

$$\mathbb{P} \left(\left| \sum_{i=1}^n X_i \right| \geq t \right) \leq 2 \exp \left(- \frac{t^2}{2n\sigma_\infty^2 + CMt} \right), \quad (3.8)$$

gdzie $M = \sup_i \|X_i\|_\infty$. Zauważmy, że aby zapewnić sobie, że (3.8) oddaje zachowanie wynikające z CTG (3.6) musimy położyć nacisk na to, aby C była rzędu $o(n)$, gdy $n \rightarrow \infty$. Z drugiej strony, ogólnie, możemy sobie pozwolić na to, aby stała C zależała od pewnych własności procesu \mathbf{X} (o ile $C = o(n)$). Z takim przypadkiem się spotykamy dla łańcuchów Markowa, dla których C zależy od punktu startowego, funkcji przejścia i jest rzędu $\log n$ (ze szczegółami można się zapoznać w twierdzeniu 3.4). Podobnie jak w przypadku niezależnym będziemy mówili, że **nierówność Bernsteina jest optymalna**, o ile nierówność (3.8) oddaje zachowanie CTG (3.6).

3.1 Nierówność Bernsteina dla m -zależnych zmiennych losowych

Przypomnijmy, że proces $\mathbf{X} = (X_i)_{i \in \mathbb{Z}}$ jest m -zależny dla $m \in \mathbb{N}$, gdy

$$X_{(-\infty, k]} \perp\!\!\!\perp X_{[k+m+1, \infty)}, \quad \forall k \in \mathbb{Z}. \quad (3.9)$$

Klasa m -zależnych zmiennych losowych była badana w wielu pracach, np. [1, 38, 10, 27, 32, 13], jednak wydaje się, że problem optymalnej nierówności Bernsteina nie był do tej pory rozpatrywany (przynajmniej nie ma do tej pory wyników, które by się zbliżały do optymalnych). Wspomnijmy, że ciągi 1-zależne są mocno związane z łańcuchami Markowa, dzięki metodzie rozdzielania (ang. the splitting method) wymyślonej przez Athreyę i Neya, która rozбивa łańcuch Markowa na bloki 1-zależne. W szczególności, każda wersja nierówności Bernsteina dla procesów 1-zależnych niemal natychmiastowo daje pewną nierówność dla łańcuchów Markowa (ale nie odwrotnie). Z drugiej strony istnieje przypuszczenie, że każdy 1-zależny proces stacjonarny jest w rzeczywistości 1-faktorem pewnego 1-zależnego łańcucha Markowa, co (gdyby było prawdziwe) ustalałoby ładną odpowiedniość pomiędzy tymi klasami procesów.

Niech $\mathbf{X} = (X_i)_{i \in \mathbb{Z}}$ będzie stacjonarnym m -zależnym ciągiem scentrowanych i ograniczonych zmiennych losowych. W tym przypadku *wariancja asymptotyczna* (porównaj z (3.7)) jest dana przez

$$\sigma_\infty^2 = \lim_{n \rightarrow \infty} \frac{1}{n} \text{Var} (X_1 + X_2 + \dots + X_n) = \mathbb{E}X_0^2 + 2 \sum_{i=1}^m \mathbb{E}X_0 X_i. \quad (3.10)$$

Nasz główny wynik jest dosyć techniczny i dlatego zaprezentujemy tutaj jedynie wniosek dla 1-faktorów m -zależnych l -łańcuchów Markowa (które odgrywają ważną rolę w teorii ciągów m -zależnych). Przypominamy, że proces $\mathbf{X} \in \mathcal{X}^{\mathbb{Z}}$ jest nazywany *k -faktorem* procesu $\mathbf{Y} \in \mathcal{Y}^{\mathbb{Z}}$ (porównaj z (2.1)), gdy istnieje funkcja $f: \mathcal{X}^k \rightarrow \mathcal{Y}$ taka, że

$$Y_i = f(X_i, X_{i+1}, \dots, X_{i+k-1}).$$

Proces \mathbf{Y} nazywa się *l -łańcuchem Markowa* gdy, dla dowolnego $k \in \mathbb{Z}$, znając terażniejszość $X_{[k, k+l-1]}$, przyszłość $X_{(k+l, \infty]}$ jest niezależna od przeszłości $X_{(-\infty, k-1]}$.

Twierdzenie 3.3. *Niech $X_i = f(Y_i)$, gdzie f jest ograniczoną funkcją mierzalną oraz $\mathbf{Y} = (Y_i)$ jest stacjonarnym, m -zależnym l -łańcuchem Markowa. Wówczas*

$$\mathbb{P} \left(\left| \sum_{i=1}^n X_i \right| \geq t \right) \leq 2(m+1) \exp \left(- \frac{t^2}{c_{m,l}(n+m+l)\sigma_\infty^2 + d_{m,l}M} \right), \quad (3.11)$$

gdzie $c_{m,l} = 2(1 + \frac{3}{2 \log(2m+2l)})^2(m+l)$, $d_{m,l} = \frac{4}{3}(1 + \frac{3}{2 \log(2m+2l)})(m+l)(m+1)$, $M = \|X_i\|_\infty$ oraz σ_∞^2 jest dana w (3.10).

Nowością w twierdzeniu 3.3 jest użycie wariancji asymptotycznej σ_∞^2 w gaussowskiej części nierówności Bernsteina zamiast używania $\sigma^2 = \mathbb{E}X_0^2$, tzn. wariancji pojedynczej zmiennej losowej. W istocie rzeczy jest łatwo otrzymać wersję nierówności (3.11), w której σ_∞^2 jest zastąpiona przez σ^2 . Zauważmy jeszcze, że z nierówności Schwarz'a wynika, że zawsze mamy $\sigma_\infty^2 \leq (m+1)\sigma^2$. Z drugiej strony może się zdarzyć, że $\sigma_\infty^2 \ll \sigma^2$, tzn. σ_∞^2 może być dowolnie mała w porównaniu z σ^2 (w przypadku ekstremalnym, $\sigma_\infty^2 = 0 < \sigma^2$). Podsumowując, nasza nierówność Bernsteina (3.11) jest optymalna (z dokładnością do stałych zależących od l i m) i warto ją stosować jedynie, gdy $\sigma_\infty^2 \ll \sigma^2$.

3.2 Nierówność Bernsteina dla ogólnych łańcuchów Markowa

Założmy, że $\mathbf{X} = (X_n)_{n \in \mathbb{N}}$ jest łańcuchem Markowa określonym na przestrzeni probabilistycznej $(\Omega, \mathcal{F}, \mathbb{P})$, przyjmującym wartości w przestrzeni mierzalnej (przeliczalnie generowanej) $(\mathcal{X}, \mathcal{B})$, z funkcją przejścia $P: \mathcal{X} \times \mathcal{B} \rightarrow [0, 1]$. Ponadto założmy, że \mathbf{X} jest *ψ -nieredukowalny, aperiodyczny i dopuszcza jedyną niezmienniczą miarę probabilistyczną* π . Jak zwykle, dla rozkładu początkowego μ na \mathcal{X} , piszemy $\mathbb{P}_\mu(\mathbf{X} \in \cdot)$ dla rozkładu łańcucha, dla którego X_0 ma rozkład μ . Będziemy pisać \mathbb{P}_x zamiast \mathbb{P}_{δ_x} , gdzie δ_x oznacza miarę Diraca w punkcie x .

Mówimy, że \mathbf{X} jest *geometrycznie ergodyczny*, gdy istnieje liczba dodatnia $\rho < 1$ oraz funkcja rzeczywista $G: \mathcal{X} \rightarrow \mathbb{R}$ należąca do $L_1(\pi)$ takie, że dla dowolnego punktu startowego $x \in \mathcal{X}$ oraz $n \in \mathbb{N}$,

$$\|P^n(x, \cdot) - \pi(\cdot)\|_{TV} \leq G(x)\rho^n, \quad (3.12)$$

gdzie $\|\cdot\|_{TV}$ oznacza normę totalnego wahania miary, $P^n(\cdot, \cdot)$ zaś jest n -krokową funkcją przejścia łańcucha.

Nasz główny rezultat jest następujący:¹

Twierdzenie 3.4. *Niech \mathbf{X} będzie geometrycznie ergodycznym łańcuchem Markowa z przestrzenią stanów \mathcal{X} oraz niech π będzie jego jedyną stacjonarną miarą probabilistyczną. Ponadto, niech $f: \mathcal{X} \rightarrow \mathbb{R}$ będzie ograniczoną funkcją mierzalną taką, że $\mathbb{E}_\pi f = 0$. Niech $x \in \mathcal{X}$. Wówczas możemy znaleźć stałe $K, \tau > 0$ zależące jedynie od x oraz funkcji przejścia $P(\cdot, \cdot)$ takie, że dla wszystkich $t > 0$,*

$$\mathbb{P}_x \left(\left| \sum_{i=0}^{n-1} f(X_i) \right| > t \right) \leq K \exp \left(- \frac{t^2}{32n\sigma_{Mrv}^2 + \tau t \|f\|_\infty \log n} \right),$$

¹Poniżej, dla pewnej wygody, kładziemy $\log(\cdot) = \ln(\cdot \vee e)$, gdzie $\ln(\cdot)$ oznacza logarytm naturalny.

gdzie

$$\sigma_{Mrv}^2 = \text{Var}_\pi(f(X_0)) + 2 \sum_{i=1}^{\infty} \text{Cov}_\pi(f(X_0), f(X_i)) \quad (3.13)$$

oznacza wariancję asymptotyczną procesu $(f(X_i))_i$.

Uwaga 3.5. Stałe K i τ są jawne. Ponadto w rozprawie podajemy ogólniejsze wersje twierdzenia 3.4 (dla nieograniczonych zmiennych losowych).

Wyjaśnijmy teraz, w jaki sposób twierdzenie 3.4 można zobaczyć w szerszym kontekście. Przypomnijmy sobie klasyczną nierówność Bernsteina w przypadku ograniczonym z twierdzenia 3.2. Prawo wielkich liczb dla łańcuchów Markowa (patrz [11, 44, 43]) gwarantuje nam, że przy założeniach i oznaczeniach twierdzenia 3.4, sumy $\frac{1}{\sqrt{n}} \sum_{i=0}^{n-1} f(X_i)$ zbiegają wg rozkładu do rozkładu normalnego $\mathcal{N}(0, \sigma_{Mrv}^2)$. Stąd nierówność otrzymana w twierdzeniu 3.4 jest odbiciem (z dokładnością do stałych) asymptotycznie normalnego zachowania sum $\frac{1}{\sqrt{n}} \sum f(X_i)$, podobnie do przypadku klasycznej nierówności Bernsteina w kontekście i.i.d. Dalej, wyraz $\log n$, który pojawia się w naszej nierówności, jest konieczny – jeśli dla wszystkich $t > 0$ mamy

$$\mathbb{P}_x \left(\left| \sum_{i=0}^{n-1} f(X_i) \right| > t \right) \leq \text{const} \cdot \exp \left(- \frac{t^2}{\text{const} \cdot n\sigma^2 + \text{const}(x) \cdot a_n t \|f\|_\infty} \right) \quad (3.14)$$

dla pewnych $a_n = o(n)$ oraz $\sigma \in \mathbb{R}$ (const oznacza tu za każdym razem pewną stałą absolutną, podczas gdy $\text{const}(x)$ zależy jedynie od x i samego łańcucha Markowa), to musimy mieć $\sigma^2 \geq \text{const} \cdot \sigma_{Mrv}^2$. Co więcej, dla pewnych geometrycznie ergodycznych łańcuchów Markowa, a_n muszą wzrastać co najmniej logarytmicznie z n (patrz [2], Section 3.3).

Nierówności koncentracyjne dla łańcuchów Markowa i procesów zostały gruntownie zbadane w literaturze (patrz np. [2, 3, 5, 6, 12, 14, 18, 23, 28, 36, 35, 41, 40, 45, 50, 59]). Pewne wyniki są poświęcone koncentracji dla ogólnych funkcji łańcucha (zwykle takie rezultaty otrzymuje się przy różnych założeniach Lipschitzowości, czy warunków ograniczenia różnic), inne idą w kierunku funkcjonałów addytywnych, które są również obiektem badań w rozprawie. Ogonowe nierówności dla funkcjonałów addytywnych są zwykle odpowiednikami nierówności Hoeffdinga czy Bernsteina. Te pierwsze nierówności nie biorą pod uwagę wariancji funkcjonału addytywnego i są wyrażane jedynie w terminach normy $\|f\|_\infty$. Często otrzymuje się je jako przypadki specjalne nierówności koncentracyjnych dla ogólnych funkcji (patrz np. [14, 45, 50]). Oszacowania typu Bernsteina postaci (3.14) są rozpatrywane np. w [2, 3, 5, 6, 12, 18, 23, 36, 35, 41, 40, 45, 59] i używają one zamienników wariancji σ^2 , które niekoniecznie zgadzają się z graniczną wariancją σ_{Mrv}^2 . W przypadku czasu ciągłego nierówności typu Bernsteina dla naturalnych odpowiedników funkcjonałów addytywnych (używające wariancji asymptotycznej) zostały otrzymane przy założeniu luki spektralnej lub warunków typu Lapunowa w [23, 36]. Dla dyskretnych łańcuchów Markowa nierówności otrzymane w [2, 3, 6, 12, 18] metodą regeneracji dają (3.14) (przy różnego rodzaju założeniach ergodyczności oraz z różnymi parametrami a_n) z σ^2 , co zgadza się z σ_{Mrv}^2 jedynie przy dodatkowym założeniu silnej aperiodyczności łańcucha. Z drugiej strony artykuły [41, 40, 50, 59] przynoszą ogólniejsze rezultaty, stosowalne dla ciągów zmiennych losowych (niekoniecznie Markowa), spełniających różne warunki mieszania. Zamienniki wariancji σ^2 , które są używane w tych pracach, są bliskie wariancji asymptotycznej, ale na ogół nie są jej równe. Dla przykładu nierówność otrzymana w [41], która zachodzi w szczególności dla geometrycznie ergodycznych łańcuchów, używa (w naszych oznaczeniach) $\sigma^2 = \text{Var}_\pi(f(X_0)) + 2 \sum_{i=1}^{\infty} |\text{Cov}_\pi(f(X_0), f(X_i))|$. Porównując to z (3.13), możemy zobaczyć, że $\sigma_{Mrv}^2 \leq \sigma^2$. W rzeczywistości możemy skonstruować przykłady, dla których iloraz tych dwóch wielkości jest dowolnie duży lub nawet $\sigma_{Mrv}^2 = 0$ oraz $\sigma^2 > 0$. Pozycja [59] dostarcza nierówność dla jednostajnie geometrycznie ergodycznych procesów, uwzględniającą pewien ukryty zamiennik wariancji σ_n^2 , który może być ograniczony z góry przez σ^2 na mocy [41] lub przez $\text{Var}_\pi(f(X_0)) + C\|f\|_\infty \mathbb{E}_\pi|f(X_0)|$, gdzie C jest stałą zależącą od własności mieszających procesu. Dla ustalonego procesu, w sytuacji niezdegenerowanej, kiedy wariancja asymptotyczna jest niezerowa, może być ona zastąpiona przez σ_n^2 , co jednak kosztuje wprowadzenie dodatkowych stałych modyfikacyjnych, zależących od łańcucha i od f .

Według naszej najlepszej wiedzy twierdzenie 3.4 jest zatem pierwszą w literaturze nierównością ogonową, którą można otrzymać dla ogólnego geometrycznie ergodycznego (niekoniecznie silnie aperiodycznego) łańcuchu Markowa i która (z dokładnością do stałych uniwersalnych) jest odbiciem prawidłowego granicznego zachowania gaussowskiego funkcjonałów addytywnych. Problem otrzymania nierówności tego typu został oficjalnie postawiony w pracy [3]. Zauważmy, że badanie ilościowe naszych problemów, związane z CTG dla ogólnych aperiodycznych łańcuchów Markowa, wydaje się być istotnie trudniejsze niż dla łańcuchów, które są silnie aperiodyczne. Dla przykładu rezultaty typu optymalnej silnej aproksymacji są znane tylko w tym drugim przypadku [42].

4 Entropia i odzyskiwanie sygnału

Niech $X \in \mathcal{X}$, $Y \in \mathcal{Y}$ będą zmiennymi losowymi, gdzie \mathcal{X} jest przestrzenią dyskretną (co najwyżej przeliczalną). W tej części szeroko używamy pojęcia (warunkowej) entropii Shannona $\mathbf{H}(X)$ ($\mathbf{H}(X|Y)$), która intuicyjnie może być opisana jako miara (jest ona zawsze nieujemna) nieuporządkowania X . Innymi słowy, im większa entropia $\mathbf{H}(X)$, tym bardziej jest niepewny wynik obserwacji zmiennej X . Oczywiście ekstremalnym przypadkiem jest tu $\mathbf{H}(X) = 0$, równoważny z X będącą stałą (jesteśmy więc pewni realizacji zmiennej losowej X). Ponadto zachodzi $\mathbf{H}(X) \leq \log |\mathcal{X}|$, z równością (dla przestrzeni skończonych) wtedy i tylko wtedy, gdy X ma jednostajny rozkład na \mathcal{X} (nie można przewidzieć wyniku X , wszystkie zdarzenia mają to samo prawdopodobieństwo). Krótko mówiąc, gdy $\mathbf{H}(X)$ rośnie, rozkład zmiennej X staje się coraz bardziej jednostajny. Formalnie,

$$\mathbf{H}(X) = - \sum_{x \in \mathcal{X}} \mathbb{P}(X = x) \log \mathbb{P}(X = x) \quad (4.1)$$

oraz

$$\mathbf{H}(X|Y) = \mathbb{E}_Y \mathbf{H}(X^{(Y)}), \quad X^{(y)} \sim p_{X|Y}(\cdot|y),$$

gdzie \mathbb{E}_Y oznacza całkowanie względem Y , a $p_{X|Y}$ oznacza regularny rozkład warunkowy zmiennej X , mając dane Y . Jeśli X jest dowolna (niekoniecznie dyskretna), to można rozszerzyć definicję entropii Shannona do

$$\mathbf{H}(X) = \sup_f \mathbf{H}(f(X)), \quad (4.2)$$

gdzie supremum bierzemy po zbiorze wszystkich (mierzalnych) funkcji zdefiniowanych na \mathcal{X} oraz przyjmujących **skończenie wiele wartości**. Jednakże takie rozszerzenie ma swoje wady, z których najbardziej istotna pochodzi z faktu, że $\mathbf{H}(X)$ jest wtedy prawie zawsze nieskończona. Żeby to zobaczyć, weźmy proces stacjonarny $X = \mathbf{X} = (X_i)_{i \in \mathbb{Z}}$. Wówczas, na mocy definicji (4.2), dla dowolnego $n \in \mathbb{N}$,

$$\mathbf{H}(\mathbf{X}) \geq \mathbf{H}(X_{[1,n]}). \quad (4.3)$$

Jednakże jest intuicyjnie jasne (ze względu na stacjonarność procesu \mathbf{X}), że $\mathbf{H}(X_{[1,n]})$ jest rzędu n (formalnie, odwzorowanie $n \rightarrow \mathbf{H}(X_{[1,n]})$ jest podaddytywne) i stąd $\mathbf{H}(\mathbf{X}) \geq n$ dla dowolnego n , a więc $\mathbf{H}(\mathbf{X}) = \infty$. Aby ominąć ten problem, dla każdego procesu stacjonarnego \mathbf{X} takiego, że X_0 jest dyskretna, wprowadzamy pojęcie **entropii procesu \mathbf{X}** (ang. entropy rate),

$$\mathbf{H}(\mathbf{X}) = \lim_{n \rightarrow \infty} \frac{1}{n} \mathbf{H}(X_{[1,n]}) = \mathbf{H}(X_0 | X_{(-\infty, -1]}). \quad (4.4)$$

Zauważmy, że $\mathbf{H}(\mathbf{X}) \leq \mathbf{H}(X_0)$ i stąd entropia $\mathbf{H}(\mathbf{X})$ jest skończona, o ile $\mathbf{H}(X_0)$ jest skończona.

Uwaga 4.1. Używamy tego samego symbolu zarówno w (4.2), jak i (4.4), ale ponieważ istotna jest jedynie definicja (4.4), więc $\mathbf{H}(\mathbf{X})$ będzie zawsze dotyczyło (4.4).

Podobnie, dla dowolnego procesu stacjonarnego $(\mathbf{X}, \mathbf{Y}) = (X_i, Y_i)_{i \in \mathbb{Z}}$, gdzie X_0, Y_0 są dyskretne oraz $\mathbf{H}(X_0 | Y_0) < \infty$, definiujemy **entropię relatywną** jako

$$\mathbf{H}(\mathbf{X}|\mathbf{Y}) = \lim_{n \rightarrow \infty} \frac{1}{n} \mathbf{H}(X_{[1,n]} | Y_{[1,n]}) = \mathbf{H}(X_0 | X_{(-\infty, -1]}, \mathbf{Y}).$$

Przypomnijmy teraz pojęcie *entropii topologicznej* (która opisuje złożoność topologiczną przestrzeni). Dla podshiftu $\mathcal{X} \subset \mathcal{X}^{\mathbb{Z}}$ jego entropia topologiczna jest dana przez

$$\mathbf{H}_{\mathcal{X}} = \lim_{n \rightarrow \infty} \frac{1}{n} |\mathcal{L}(n)|, \quad (4.5)$$

gdzie $\mathcal{L}(n)$ jest rodziną wszystkich słów długości n , która pojawiają się w \mathcal{X} . Można pokazać pewną wersję zasady wariacyjnej dla $\mathbf{H}_{\mathcal{X}}$, a mianowicie,

$$\mathbf{H}_{\mathcal{X}} = \sup_{\mathbf{X} \in \mathcal{M}_{\mathcal{X}}} \mathbf{H}(\mathbf{X}). \quad (4.6)$$

Dzięki górnej półciągłości entropii procesu, powyższe supremum jest zawsze osiągane przez pewien proces \mathbf{X} . Każdy taki proces \mathbf{X} (w istocie rzeczy chodzi o jego rozkład) jest nazywany *miarą o maksymalnej entropii*. Jeśli istnieje dokładnie jedna miara o maksymalnej entropii, to mówimy, że \mathcal{X} jest *wewnętrznie ergodyczny*.

Wszystkie te „typy” entropii mają wiele interpretacji i zastosowań. Wspomnijmy kilka z nich, żeby uświadomić sobie, dlaczego to pojęcie jest tak fundamentalne i uniwersalne.

- (Struktura miar produktowych). Załóżmy, że zmienne losowe $X_i \in \mathcal{X}$ przyjmują skończenie wiele wartości oraz \mathbf{X} jest ergodyczny. Rozważmy rozkład zmiennej $X = X_{[1,n]} \in \mathcal{X}^n$. Chcielibyśmy (w przybliżeniu) opisać nośnik zmiennej X (przez nośnik rozumiemy tutaj dowolny podzbiór S taki, że $\mathbb{P}(X \in S) = 1$). Jak wygląda rozkład μ zmiennej X na S ? Okazuje się, że w zasadzie możemy wziąć za S zbiór **punktów typowych entropijnie**,

$$S = T_{ent,\varepsilon} = \{x \in \mathcal{X}^n \mid 2^{(n-\varepsilon)\mathbf{H}(\mathbf{X})} \leq \mathbb{P}(X = x) \leq 2^{(n+\varepsilon)\mathbf{H}(\mathbf{X})}\} \quad (4.7)$$

(ten fakt jest znany pod nazwą *asymptotycznego równomiernego rozłożenia*, patrz Theorem I.7.1 w [52]). Intuicyjnie, o X (dla dostatecznie dużych n) można myśleć jako o **równomiernym rozkładzie** na zbiorze S , który ma w przybliżeniu $2^{n\mathbf{H}(\mathbf{X})}$ elementów.

- (Kompresja sygnału). Przypuśćmy, że mamy dany proces i.i.d. (zwykle binarny) $\mathbf{X} = (X_i)_{i \in \mathbb{N}}$ taki, że $X_i \in \mathcal{X}$ oraz zbiór \mathcal{X} jest skończony. Dla danego $n \in \mathbb{N}$ chcemy skompresować $X = X_{[1,n]}$, tzn. znaleźć **koder** $f: \mathcal{X}^n \rightarrow \mathcal{Y}$ oraz **dekoder** $D: \mathcal{Y} \rightarrow \mathcal{X}^n$ w taki sposób, aby **prawdopodobieństwo błędu** $\mathbb{P}(D(E(X)) \neq X)$ było dowolnie małe. Oczywiście w tym problemie chcemy, aby \mathcal{Y} był możliwie mały. Okazuje się, że (z grubsza) można dokonać kompresji X , o ile $|\mathcal{Y}| > n\mathbf{H}(X_1)$. Z drugiej strony nie można uzyskać kompresji X , gdy $|\mathcal{Y}| < n\mathbf{H}(X_1)$. W tym sensie $n\mathbf{H}(X_1)$ jest naturalną barierą dla problemu kompresji.
- (Powtarzanie wzorca). Niech \mathbf{X} będzie ergodycznym procesem stacjonarnym. Dla danego $n \in \mathbb{N}$, jak długo musimy czekać, aby słowo $X_{[1,n]}$ powtórzyło się w całym ciągu $\mathbf{X} = (X_i)_{i \in \mathbb{N}}$? Można pokazać (patrz Theorem II.5.1 w [52]), że dla

$$R_n = \inf\{k \in \mathbb{N} \mid X_{[k+1,k+n]} = X_{[1,n]}\}$$

mamy $\lim_{n \rightarrow \infty} \frac{1}{n} \log_2 R_n = \mathbf{H}(\mathbf{X})$, tzn. $R_n \sim 2^{n\mathbf{H}(\mathbf{X})}$ (o ile $\mathbf{H}(\mathbf{X}) > 0$). Ta asymptotyka ma swoją następującą intuicyjną konsekwencję: im mniejsza entropia procesu \mathbf{X} (a więc, im mniej jest „skomplikowany” proces \mathbf{X}), „tym częściej” będziemy widzieć powtórki wzorców w \mathbf{X} . Dodajmy, że powyższe twierdzenie jest wybitnie nieefektywne dla procesów o zerowej entropii. W przypadku ekstremalnym, w którym \mathbf{X} jest okresowy, tzn. $S^p \mathbf{X} = \mathbf{X}$ (co w oczywisty sposób implikuje $\mathbf{H}(\mathbf{X}) = 0$), stowarzyszony proces R_n jest ograniczony przez p jednostajnie dla wszystkich n !

- (Izomorfizm procesów). Słynne twierdzenie Ornsteina i Friedmana [20] mówi, że dwa układy, które są słabo Bernoulli i mają tę samą entropię, są izomorficzne. W terminach procesów oznacza to, że jeśli procesy \mathbf{X} oraz \mathbf{Y} są stacjonarne, słabo Bernoulli (równoważnie, β -mieszające) oraz $\mathbf{H}(\mathbf{X}) = \mathbf{H}(\mathbf{Y})$, to są one izomorficzne. Zauważmy, że w szczególności otrzymujemy raczej nietrywialny wniosek: każdy mieszający łańcuch Markowa (na skończonej przestrzeni stanów) jest izomorficzny z pewnym procesem i.i.d.!

- (Fizyczne własności miar o maksymalnej entropii) Niech \mathcal{X} będzie podshiftem, a \mathbf{X} miarą o maksymalnej entropii. Okazuje się, że często \mathbf{X} ma „dobre” dodatkowe własności fizyczne. Dla przykładu, jeśli proces \mathbf{X} (tzn. jego rozkład) jest jedyny, to \mathbf{X} musi być ergodyczny. Ponadto, raczej w sposób naturalny, oczekujemy, że \mathbf{X} jest miarą Gibbsa, tzn.

$$c2^{-n\mathbf{H}\mathbf{x}} \leq \mathbb{P}(X_{[1,n]} = x_{[1,n]}) \leq C2^{-n\mathbf{H}\mathbf{x}} \quad (4.8)$$

dla pewnych stałych numerycznych c, C oraz wszystkich $x_{[1,n]} \in \mathcal{X}^n$, dla których powyższe prawdopodobieństwo jest dodatnie. (Por. (4.8) z (4.7).) Jeśli myślimy o innych konsekwencjach, to (4.8) implikuje np., że proces \mathbf{X} musi być *quasi-Bernoulli*, tzn.

$$k\mathbb{P}(X_{[1,n]} = x_{[1,n]}) \leq \mathbb{P}_{X_{[-m,0]}=x_{[-m,0]}}(X_{[1,n]} = x_{[1,n]}) \leq K\mathbb{P}(X_{[1,n]} = x_{[1,n]}) \quad (4.9)$$

dla pewnych stałych k, K zależących od c, C z (4.8).

Przypomnijmy, że jeśli rozpatrujemy jedynie ograniczenie dolne w (4.8), to otrzymujemy definicję tzw. *własności Gibbsa*. Naturalna miara o maksymalnej entropii dla układów \mathcal{B} -wolnych nie spełnia własności Gibbsa. W szczególności otrzymujemy szeroką klasę podshiftów wewnętrznie ergodycznych, dla których miara o maksymalnej entropii **nie jest Gibbsa**.

4.1 Entropia iloczynu procesów

Niech $\mathbf{X} = (X_i)_{i \in \mathbb{Z}}$ i $\mathbf{Y} = (Y_i)_{i \in \mathbb{Z}}$ będą rzeczywistymi procesami o skończonej wielu wartościach, przy czym proces $(\mathbf{X}, \mathbf{Y}) = (X_i, Y_i)_i$ jest stacjonarny. Załóżmy dodatkowo, że $Y_i \in \{0, 1\}$ dla $i \in \mathbb{Z}$ oraz $0 < \mathbb{P}(Y_0 = 1) < 1$. W tej części badamy entropię relatywną iloczynu procesów \mathbf{X} and \mathbf{Y} , przy zadanym procesie \mathbf{Y} , a więc wielkość $\mathbf{H}(\mathbf{X} \cdot \mathbf{Y} \mid \mathbf{Y})$.

Uwaga 4.2. Zauważmy, że jeśli $\mathbf{H}(\mathbf{Y}) = 0$, co zachodzi dla podshiftów \mathcal{B} -wolnych, których dynamika jest dla nas główną motywacją badania problemu entropii iloczynu, to $\mathbf{H}(\mathbf{X} \cdot \mathbf{Y} \mid \mathbf{Y}) = \mathbf{H}(\mathbf{X} \cdot \mathbf{Y})$. Jednakże wydaje się, że znacznie łatwiej jest poradzić sobie z relatywną wersją entropii procesu, $\mathbf{H}(\mathbf{X} \cdot \mathbf{Y} \mid \mathbf{Y})$, niż z jej wersją bezwarunkową $\mathbf{H}(\mathbf{X} \cdot \mathbf{Y})$.

W rozprawie odpowiadamy na następujące pytania postawione w nieco słabszej wersji w artykule [33] (patrz Question 1 tamże):

1. Czy istnieje ogólny wzór dla entropii $\mathbf{H}(\mathbf{X} \cdot \mathbf{Y} \mid \mathbf{Y})$?
2. Czy zawsze mamy $\mathbf{H}(\mathbf{X} \cdot \mathbf{Y} \mid \mathbf{Y}) > 0$, o ile $\mathbf{H}(\mathbf{X}) > 0$?
3. Czy możemy mieć $\mathbf{H}(\mathbf{X} \cdot \mathbf{Y} \mid \mathbf{Y}) = \mathbf{H}(\mathbf{X}) > 0$?

Poniżej, dla dowolnego $A \subset \Omega$ takiego, że $\mathbb{P}(A) > 0$, będziemy pisać $\mathbf{H}_A(X)$ dla entropii Shannona na A , tzn. zastępujemy prawdopodobieństwo \mathbb{P} jego wersją warunkową $\mathbb{P}_A(\cdot) = \mathbb{P}(\cdot \cap A) / \mathbb{P}(A)$ i rozważamy X na $(\Omega, \mathcal{F}, \mathbb{P}_A)$. Innymi słowy, po prostu zastępujemy \mathbb{P} przez \mathbb{P}_A w (4.1). Ta sama umowa obowiązuje w przypadku wersji warunkowej entropii Shannona.

Niech $\mathbf{R} = \mathbf{R}(\mathbf{Y}) = (R_i)_{i \in \mathbb{Z}}$ będzie procesem kolejnych *czasów wizyt* procesu \mathbf{Y} do stanu 1 (aby uzyskać dokładny wzór na \mathbf{R} , należy zastąpić A przez $\{1\}$ w (1.1)). Proces ten jest dobrze zdefiniowany (tzn. $-\infty < R_i < \infty$ dla wszystkich i) na $\{Y_0 = 1\}$ (dzięki twierdzeniu Poincarégo o powracaniu) i na całej przestrzeni Ω , o ile \mathbf{Y} jest ergodyczny.

Twierdzenie 4.3 (Odpowiedź na pytanie 1). *Przy naszych założeniach,*

$$\mathbf{H}(\mathbf{X} \cdot \mathbf{Y} \mid \mathbf{Y}) = \mathbb{P}(Y_0 = 1) \mathbf{H}_{Y_0=1}(X_0 \mid X_{\{R_{-1}, R_{-2}, \dots\}}, \mathbf{Y}). \quad (4.10)$$

Jeśli dodatkowo $\mathbf{X} \amalg \mathbf{Y}$, to

$$\mathbf{H}(\mathbf{X} \cdot \mathbf{Y} \mid \mathbf{Y}) = \mathbb{P}(Y_0 = 1) \mathbb{E}_{Y_0=1} \mathbf{H}(X_0 \mid X_{\{r_{-1}, r_{-2}, \dots\}}) \Big|_{r_{-i}=R_{-i}}. \quad (4.11)$$

Stosując łatwe oszacowania do (4.11), otrzymujemy następujący rezultat:

Wniosek 4.4 (odpowiedź na pytanie 2). Przy naszych założeniach, jeśli dodatkowo $0 < \mathbf{H}(\mathbf{X})$ oraz $\mathbf{X} \perp\!\!\!\perp \mathbf{Y}$, to $\mathbb{P}(Y_0 = 1) \mathbf{H}(\mathbf{X}) \leq \mathbf{H}(\mathbf{X} \cdot \mathbf{Y} \mid \mathbf{Y}) \leq \mathbb{P}(Y_0 = 1) \mathbf{H}(X_0)$. W szczególności $\mathbf{H}(\mathbf{X} \cdot \mathbf{Y} \mid \mathbf{Y}) > 0$, o ile $\mathbf{H}(\mathbf{X}) > 0$.

Sytuacja zmienia się diametralnie, jeśli pozwolimy na pewną zależność procesów \mathbf{X} i \mathbf{Y} – wówczas może się zdarzyć, że

$$\mathbf{H}(\mathbf{X} \cdot \mathbf{Y}) = 0 = \mathbf{H}(\mathbf{Y}) < \mathbf{H}(\mathbf{X}). \quad (4.12)$$

Przykład 4.5 (odpowiedź na pytanie 2). Weźmy proces stacjonarny (\mathbf{X}, \mathbf{Y}) . Heurystycznie, gdy \mathbf{X} jest przemnożony przez \mathbf{Y} , część procesu \mathbf{X} na nośniku procesu \mathbf{Y} pozostaje niezmienną, gdy tymczasem część procesu \mathbf{X} na nośniku procesu $\mathbf{1} - \mathbf{Y}$ znika. Zatem, jeśli \mathbf{X} jest taki, że jego entropia jest zero na nośniku procesu \mathbf{Y} i dodatnia na nośniku procesu $\mathbf{1} - \mathbf{Y}$, to otrzymujemy (4.12). Bardziej formalnie, dla dowolnego połączenia (stacjonarnego couplingu) $(\mathbf{Z}, \mathbf{W}, \mathbf{U})$, gdzie \mathbf{U} jest binary, rozważmy

$$\mathbf{A} = \mathbf{U} \cdot \mathbf{Z} + (\mathbf{1} - \mathbf{U})\mathbf{W}.$$

Zauważmy, że (\mathbf{A}, \mathbf{U}) jest stacjonarny i każdy stacjonarny proces (\mathbf{X}, \mathbf{Y}) może być zrealizowany jako (\mathbf{A}, \mathbf{U}) poprzez wzięcie $\mathbf{W} = \mathbf{Z} = \mathbf{X}$, $\mathbf{U} = \mathbf{Y}$. I teraz, jeśli założymy, że $\mathbf{W} \perp\!\!\!\perp \mathbf{U} \perp\!\!\!\perp \mathbf{Z}$ oraz $\mathbf{H}(\mathbf{Z}) = \mathbf{H}(\mathbf{U}) = 0 < \mathbf{H}(\mathbf{W})$ i $\mathbf{U} \neq \mathbf{1}$, to ze względu na podaddytywność entropii mamy

$$\mathbf{H}(\mathbf{A} \cdot \mathbf{U}) = \mathbf{H}(\mathbf{U} \cdot \mathbf{Z}) \leq \mathbf{H}(\mathbf{U}) + \mathbf{H}(\mathbf{Z}) = 0$$

i z wniosku 4.4 wynika, że

$$\mathbf{H}(\mathbf{A}) = \mathbf{H}(\mathbf{A} \mid \mathbf{Z}, \mathbf{U}) = \mathbf{H}((\mathbf{1} - \mathbf{U})\mathbf{W} \mid \mathbf{Z}, \mathbf{U}) = \mathbf{H}((\mathbf{1} - \mathbf{U})\mathbf{W} \mid \mathbf{U}) \stackrel{\text{wniosek 4.4}}{\geq} \mathbb{P}(U_0 = 0) \mathbf{H}(\mathbf{W}) > 0$$

(ażeby otrzymać drugą równość, trzeba użyć definicji entropii warunkowej i zastosować zasadę reetyki-etowania).

W końcu podajemy przykład, w którym \mathbf{X} oraz \mathbf{Y} mogą być zrekonstruowane z procesu $\mathbf{X} \cdot \mathbf{Y}$ (w szczególności mamy $\mathbf{H}(\mathbf{X}) = \mathbf{H}(\mathbf{X} \cdot \mathbf{Y})$).

Przykład 4.6 (odpowiedź na pytanie 3). Niech $(\xi_i)_{i \in \mathbb{Z}}$ będzie ciągiem i.i.d. zmiennych losowych takim, że $\mathbb{P}(\xi_0 = 0) = \mathbb{P}(\xi_0 = 1) = \frac{1}{2}$, niech $F: \{0, 1\}^2 \rightarrow \{1, 2, 3, 4\}$ będzie dowolną funkcją 1-1 (tzn. mamy do czynienia z reetykietowaniem) i połóżmy $X_i = F(\xi_i, \xi_{i+1})$. Dalej, niech \mathbf{Y} będzie niezależny od procesu \mathbf{X} oraz $\mathbf{Y} \sim \frac{1}{2}(\delta_{\mathbf{x}} + \delta_{S_{\mathbf{x}}})$, gdzie $x_{2i} = 0 = 1 - x_{2i+1}$ dla $i \in \mathbb{Z}$. Ponieważ \mathbf{X} jest łańcuchem Markowa i F jest 1-1, więc mamy $\mathbf{H}(\mathbf{X}) = \mathbf{H}(X_1 \mid X_0) = \mathbf{H}(\xi_1, \xi_2 \mid \xi_0, \xi_1) = \mathbf{H}(\xi_2 \mid \xi_0, \xi_1) = \mathbf{H}(\xi_2) = \log 2$. Ponadto $\mathbb{P}_{Y_0=1}(R_{-1} = 2) = 1$ i dlatego ze względu na (4.11), $\mathbf{H}(\mathbf{X} \cdot \mathbf{Y}) = \frac{1}{2} \mathbf{H}(X_0 \mid X_{-2}) = \frac{1}{2} \mathbf{H}(X_0) = \log 2$, gdzie użyliśmy niezależności X_0 od X_{-2} . Podsumowując,

$$\mathbf{H}(\mathbf{X}) = \mathbf{H}(\mathbf{X} \cdot \mathbf{Y}). \quad (4.13)$$

Możemy nawet wzmocnić (4.13). Zauważmy, że ponieważ F nie osiąga wartości 0, więc możemy odzyskać zarówno \mathbf{X} , jak i \mathbf{Y} z $\mathbf{X} \cdot \mathbf{Y}$. Rzeczywiście, każda zerowa współrzędna w $\mathbf{X} \cdot \mathbf{Y}$ natychmiast wyznacza \mathbf{Y} . Ponadto, z samej definicji procesu ξ , ξ (i stąd \mathbf{X}) można zrekonstruować, o ile znamy nieparzyste, bądź parzyste współrzędne w \mathbf{X} . Stąd, jeśli tylko dostaniemy proces \mathbf{Y} z procesu $\mathbf{X} \cdot \mathbf{Y}$, to łatwo znaleźć proces \mathbf{X} .

4.2 Odzyskiwanie sygnału

Przypomnijmy słynny problem Furstenberga (z 1967 r.) odszumiania (zaszumionego) sygnału. Podstawowe pytanie zadane w [21] brzmiało, kiedy można odzyskać sygnał \mathbf{Z} z perturbacji postaci $\mathbf{Z} + \mathbf{W}$, gdzie \mathbf{Z} i \mathbf{W} są rzeczywistymi procesami stacjonarnymi. Aby rozwiązać ten problem, Furstenberg wprowadził pojęcie **absolutnej rozłączności procesów** (znacznie silniejsze niż zwykła niezależność) i udowodnił, że ta własność wystarcza do odszumienia procesu \mathbf{Z} z $\mathbf{Z} + \mathbf{W}$ (dodatkowe założenie całkowalności użyte w [21], jak wykazał znacznie później Garbit [24], okazało się niepotrzebne). W tym samym duchu można interpretować $\mathbf{X} \cdot \mathbf{Y}$ jako stracony sygnał (przypomnijmy, że $Y_i \in \{0, 1\}$) i zapytać, czy mimo wszystko można (bądź nie można) odzyskać \mathbf{X} z $\mathbf{X} \cdot \mathbf{Y}$. Oczywiście, jeśli $\mathbf{H}(\mathbf{X} \cdot \mathbf{Y}) < \mathbf{H}(\mathbf{X})$, to nie ma szans na odzyskanie procesu \mathbf{X} , stąd naturalnym jest przeformułowanie pytania 3 w następujący sposób:

3'. Czy istnieje naturalne kryterium na $\mathbf{H}(\mathbf{X} \cdot \mathbf{Y}) < \mathbf{H}(\mathbf{X})$ przy założeniu, że $\mathbf{H}(\mathbf{X}) > 0$?

Uwaga 4.7. Zauważmy, że gdyby przestrzenie stanów procesów \mathbf{X} i \mathbf{Y} były zawarte w zbiorze dodatnich liczb rzeczywistych, to nasz problem zredukowałby się do problemu odszumiania Furstenberga $\mathbf{Z} + \mathbf{W}$, gdzie $\mathbf{Z} = \log \mathbf{X}$ oraz $\mathbf{W} = \log \mathbf{Y}$. W tym sensie jest ważne, że zmienne losowe Y_i przyjmują wartość zero.

Uwaga 4.8. W klasycznym problemie Furstenberga sygnał \mathbf{X} jest reprezentowany przez proces o zerowej entropii (tzn. proces deterministyczny). W naszym problemie jest odwrotnie. To proces \mathbf{X} nie jest deterministyczny i jest on zaburzany przez proces deterministyczny \mathbf{Y} , więc interpretacja poprzez klasyczną sytuację sumy nie jest zbyt precyzyjna. Niemniej, jest jasna analogia problemu, a problem ubytku entropii jest sam w sobie interesujący (patrz również następną uwagę).

Uwaga 4.9. Podobny (a tak naprawdę znacznie ogólniejszy) problem odszumiania sygnału był badany przez Furtenberga, Peresa i Weissa w [22]. Niech $\mathbf{X}^{(i)} = \left(X_j^{(i)} \right)_{j \in \mathbb{Z}}$, gdzie $i \in \mathbb{N}$, będzie rodziną procesów i niech \mathbf{U} będzie procesem przyjmującym wartości w \mathbb{N} . Zakładamy, że wszystkie te procesy są wspólnie stacjonarne. Kładziemy

$$\mathbf{X}^{(\mathbf{U})} = \left(X_i^{(\mathbf{U}_i)} \right)_{i \in \mathbb{Z}} \quad (4.14)$$

(mówiąc nieformalnie, proces \mathbf{U} określa wybór z rodziny procesów). Aby pokazać możliwość odszumienia procesu \mathbf{U} z $\mathbf{X}^{(\mathbf{U})}$, autorzy pracy [22] wprowadzili pojęcie **podwójnej rozłączności** procesów. Mówimy, że proces \mathbf{A} jest **podwójnie rozłączny (PR)** z procesem \mathbf{B} , gdy każde samopołączenie procesu \mathbf{A} jest absolutnie rozłączne z procesem \mathbf{B} . Innymi słowy, jeśli $(\mathbf{A}', \mathbf{A}'', \mathbf{B}')$ jest procesem stacjonarnym takim, że $\mathbf{A}', \mathbf{A}'' \sim \mathbf{A}$ oraz $\mathbf{B}' \sim \mathbf{B}$, to $(\mathbf{A}', \mathbf{A}'') \perp \mathbf{B}'$. Najbardziej podstawowy przykład PR procesów otrzymujemy rozpatrując \mathbf{A} deterministyczny (wówczas każde samopołączenie jest również o zerowej entropii), a \mathbf{B} ma trywialną σ -algebrę ogonową (zauważmy jednocześnie, że jeśli \mathbf{A} jest PR z procesem \mathbf{B} , to **koniecznie** $\mathbf{H}(\mathbf{A}) = 0$ oraz \mathbf{B} jest ergodyczny). Główny rezultat pracy [22] można podsumować (z grubsza) następująco. Przypuśćmy, że $\mathbf{X}^{(i)}$ dla $i \in \mathbb{N}$ oraz \mathbf{U} są wspólnie stacjonarne. Jeśli \mathbf{U} jest PR z każdym z procesów $\mathbf{X}^{(i)}$ dla $i \in \mathbb{N}$, to można odzyskać proces \mathbf{U} z procesu $\mathbf{X}^{(\mathbf{U})}$.

Wyjaśnijmy, jak można użyć tego twierdzenia w naszym kontekście mnożenia procesów i pytania 3'. Rozważmy dwa procesy $\mathbf{X}^{(i)}$, dla $i \in \{0, 1\}$, gdzie

$$X_j^{(i)} = iX_j \quad (4.15)$$

i weźmy $\mathbf{U} = \mathbf{Y}$. Wówczas $\mathbf{X}^{(\mathbf{U})} = \mathbf{X} \cdot \mathbf{Y}$ i twierdzenie powyższe mówi nam, że możemy odzyskać \mathbf{Y} z procesu $\mathbf{X} \cdot \mathbf{Y}$, o ile \mathbf{Y} jest PR z \mathbf{X} . Zauważmy, że ponieważ zakładamy, że $\mathbf{H}(\mathbf{X}) > 0$, więc nie możemy zamienić rolami \mathbf{X} i \mathbf{Y} i stąd problem, który rozważamy w rozprawie (np. ubytku entropii dla iloczynu), jest uzupełnieniem problemu odszumiania badanego w [22].

Uwaga 4.10. Byłoby interesujące znaleźć ogólne kryterium gwarantujące, że \mathbf{X} może być odzyskany z iloczynu $\mathbf{X} \cdot \mathbf{Y}$ (jak to widzieliśmy w przykładzie 4.6).

Jak poprzednio, niech $\mathbf{X} = (X_i)_{i \in \mathbb{Z}}$ oraz $\mathbf{Y} = (Y_i)_{i \in \mathbb{Z}}$ będą rzeczywistymi procesami o skończonej wielościach takimi, że $(\mathbf{X}, \mathbf{Y}) = (X_i, Y_i)_i$ jest stacjonarny, przy czym $Y_i \in \{0, 1\}$ dla $i \in \mathbb{Z}$ oraz $0 < \mathbb{P}(Y_0 = 1) < 1$. W tej części zakładamy dodatkowo, że \mathbf{X} i \mathbf{Y} są niezależne, $\mathbf{H}(\mathbf{Y}) = 0 < \mathbf{H}(\mathbf{X})$ oraz \mathbf{Y} jest ergodyczny. Nasz główny rezultat podaje kryterium na spadek entropii.

Twierdzenie 4.11 (odpowiedź na pytanie 3'). *Przy naszych założeniach,*

$$\mathbf{H}(\mathbf{X} \cdot \mathbf{Y} \mid \mathbf{Y}) \leq \mathbf{H}(\mathbf{X}) - \mathbb{P}(Y_0 = 1)^2 \mathbb{E}_{Y_0=1} \mathbf{H}(X_{[1, r_1]} \mid X_{(-\infty, 0]}, X_{\{r_1, r_2, \dots\}}) \Big|_{r_i=R_i}.$$

W szczególności, $\mathbf{H}(\mathbf{X} \cdot \mathbf{Y} \mid \mathbf{Y}) \leq \mathbf{H}(\mathbf{X}) - \mathbb{P}(Y_0 = 1)^2 \sum_{k=1}^{\infty} \mathbb{P}_{Y_0=1}(R_1 = k) \mathbf{H}(X_{[1, k]} \mid X_{(-\infty, 0] \cup [k, \infty)})$.

Zatem, aby sprawdzić, czy $\mathbf{H}(\mathbf{X} \cdot \mathbf{Y}) < \mathbf{H}(\mathbf{X})$, wystarczy sprawdzić, kiedy powyższa suma (formalnie) nieskończona jest dodatnia. Niech $\mathcal{T}_{double} = \bigcap_{i \geq 0} \sigma(X_{(-\infty, -i]}, X_{[i, \infty)})$ oznacza **podwójną ogonową σ -algebrę** (dla \mathbf{X}) i zauważmy, że dla dostatecznie dużych (parzystych) $k \in \mathbb{N}$ mamy

$$\begin{aligned} \mathbf{H}(X_{[1, k]} | X_{(-\infty, 0] \cup [k, \infty)}) &\geq \mathbf{H}(X_{k/2} | X_{(-\infty, 0] \cup [k, \infty)}) \\ &= \mathbf{H}(X_0 | X_{(-\infty, -k/2] \cup [k/2, \infty)}) \approx \mathbf{H}(X_0 | \mathcal{T}_{double}). \end{aligned}$$

Stąd, ponieważ każdy proces słabo Bernoulli (równoważnie, β -mieszający) musi mieć trywialną podwójną σ -algebrę ogonową \mathcal{T}_{double} (w szczególności $\mathbf{H}(X_0 | \mathcal{T}_{double}) = \mathbf{H}(X_0)$), więc natychmiast otrzymujemy następujący wniosek:

Wniosek 4.12. *Oprócz naszych dotychczasowych założeń przyjmijmy dodatkowo, że $\mathbf{X} \mathbf{I} \mathbf{Y}$, $\mathbf{H}(\mathbf{X}) > 0$, \mathbf{X} jest słabo Bernoulli oraz $\mathbb{P}_{Y_0=1}(R_1 = k) > 0$ dla nieskończenie wielu $k \in \mathbb{N}$. Wówczas $\mathbf{H}(\mathbf{X} \cdot \mathbf{Y}) < \mathbf{H}(\mathbf{X})$.*

5 Ciśnienie topologiczne i miary Gibbsa

Ciśnienie topologiczne Ciśnienie topologiczne jest naturalnym uogólnieniem pojęcia entropii topologicznej. Ponadto jest ono jednym z głównych pojęć formalizmu termodynamicznego, który z kolei odgrywa istotną rolę w rozwoju teorii układów dynamicznych. Dodajmy, że zasada wariacyjna dla ciśnienia topologicznego jest naturalnym pomostem łączącym dynamikę topologiczną i miarową. Związki pomiędzy tymi dynamikami są często wykorzystywane w zastosowaniach, m.in. badaniach wykładników Lapunowa, wymiarów fraktalnych, widm multi-fraktalnych, naturalnych miar niezmienniczych (np. miar o maksymalnej entropii, fizycznych, SRB, o zerowej temperaturze, czy miar o maksymalnym wymiarze), i zbiorów obrotu, patrz [7, 30, 39, 47, 49] oraz bibliografia tamże. Dodajmy, że ciśnienie topologiczne ma zastosowanie zarówno w matematyce, jak i pokrewnych dziedzinach nauki, takich jak fizyka statystyczna, czy biologia matematyczna, patrz [4, 16, 17, 15, 25, 54] oraz bibliografia tamże. Przegląd zagadnień związanych z entropią i ciśnieniem czytelnik może znaleźć w książkach i artykułach przeglądowych [7, 29, 39, 49, 56]. Zauważmy, że istnieje gałąź matematyki, która zajmuje się obliczalnością ciśnienia topologicznego. W skrócie chodzi o odpowiedź na następujące pytanie (kluczowe z punktu widzenia zastosowań): dla jakich podshiftów \mathcal{X} istnieje program komputerowy, który jest w stanie znaleźć $\mathcal{P}_{\mathcal{X}}$ (patrz [9] oraz bibliografia tamże).

Niech (\mathcal{X}, S) będzie podshiftem, $\varphi: \mathcal{X} \rightarrow \mathbb{R}$ zaś funkcją **ciągłą** (zwaną **potencjałem**). Potencjał nazywamy **lokalnym**, jeśli zależy on tylko od skończenie wielu współrzędnych. Dla danego podshiftu $\mathcal{X} \subset \mathcal{X}^{\mathbb{Z}}$ **ciśnienie topologiczne**, $\mathcal{P}_{\mathcal{X}, \varphi}$, **podshiftu** \mathcal{X} jest dane przez

$$\mathcal{P}_{\mathcal{X}, \varphi} = \lim_{n \rightarrow \infty} \frac{1}{n} \log_2 \sum_{\mathbf{A} \in \mathcal{L}^{(n)}} 2^{\sup_{\mathbf{A}} S_n \varphi(\mathbf{x})}, \quad (5.1)$$

gdzie $S_n = \sum_{i=1}^n S^i$, a $\mathcal{L}^{(n)}$ oznacza zbiór słów długości n , które pojawiają się w \mathcal{X} . Następująca **zasada wariacyjna (VP)** jest dobrze znana (patrz [57], Theorem 4.1):

$$\mathcal{P}_{\mathcal{X}, \varphi} = \sup_{\mathbf{X} \in \mathcal{M}_{\mathcal{X}}} [\mathbf{H}(\mathbf{X}) + \mathbb{E}\varphi(\mathbf{X})]. \quad (5.2)$$

Jest jasne, że jeśli weźmiemy $\varphi = 0$, to (5.1) i (5.2) redukują się do ich odpowiedników dla entropii topologicznej (przypomnijmy (4.5) oraz (4.6)). Zauważmy, że odwzorowanie $\mathbf{X} \rightarrow \mathbf{H}(\mathbf{X}) + \mathbb{E}\varphi(\mathbf{X})$ jest górnio półciągłe (w słabej topologii) i stąd wynika, że zawsze istnieje pewien optymalny proces \mathbf{X} osiągający supremum w (5.2). Proces ten (a raczej jego rozkład) nazywamy **stanem równowagi**. Jeśli miara ta jest jedyna, to musi być ona ergodyczna (używamy tego samego argumentu co w Theorem 14.25, point 2 w [26]). Ponadto oczekuje się, że zwykle stany równowagi są miarami **Gibbsa**, tzn., dla pewnych stałych numerycznych c, C oraz dowolnych $\mathbf{x} \in \mathcal{X}$, $n \in \mathbb{N}$, $\mathbf{y} \in [x_{[1, n]}]$ ($[\cdot]$ oznacza zbiór cylindryczny),

$$c \leq \frac{\mathbb{P}(X_{[1, n]} = x_{[1, n]})}{2^{\sum_{k=0}^{n-1} \varphi(S^k \mathbf{y}) - n\mathcal{P}}} \leq C. \quad (5.3)$$

Można pokazać, że powyższa stała \mathcal{P} musi być równa ciśnieniu topologicznemu podshiftu \mathcal{X} (z domyślnym potencjałem φ). W szczególności, jeśli $\varphi = 0$, to wracamy do (4.8). Dodatkowo można pokazać, że każda miara Gibbsa musi być quasi-Bernoulli (przypominamy (4.9)).

Dodajmy ponadto, że pojęcie miary Gibbsa pochodzi z fizyki statystycznej [48, 34] i odpowiada ono idei stanu równowagi skomplikowanych układów fizycznych. Miary te okazały się być również interesującym obiektem badań z punktu widzenia dynamiki i odgrywają one ważną rolę w teorii ergodycznej (patrz np. [8, 53]).

Układy \mathcal{B} -wolne Badanie układów \mathcal{B} -wolnych częściowo wynika z zainteresowania własnościami funkcji Möbiusa $\mu: \mathbb{Z} \rightarrow \{-1, 0, 1\}$. Przypomnijmy, że liczba całkowita $z \in \mathbb{Z}$ nazywa się *bezkwadratową*, gdy nie dzieli się ona przez żaden kwadrat liczby pierwszej oraz, że μ jest dana przez

$$\mu(z) = \begin{cases} 1, & \text{gdy } z \text{ jest bezkwadratowa z parzystą liczbą czynników pierwszych,} \\ -1, & \text{gdy } z \text{ jest bezkwadratowa z nieparzystą liczbą czynników pierwszych,} \\ 0, & \text{w przeciwnym wypadku.} \end{cases} \quad (5.4)$$

Arytmetyczna funkcja Möbiusa jest jedną z najbardziej fundamentalnych funkcji w teorii liczb. Wspomnijmy jedynie kilka ważnych faktów związanych z μ :

- Jest ona związana z funkcją Riemanna poprzez szereg Dirichleta, $\frac{1}{\zeta(s)} = \sum_{n \geq 1} \mu(n)/n^s$.
- Twierdzenie o rozkładzie liczb pierwszych (liczba liczb pierwszych pomiędzy 0 i $n \in \mathbb{N}$ jest w przybliżeniu równa $n/\ln n$) jest równoważne warunkowi $\sum_{n \leq N} \mu(n) = o(N)$.
- Gdybyśmy mogli wzmocnić warunek powyżej do stwierdzenia, że dla dowolnego $\varepsilon > 0$ (wiadomo już, że $\varepsilon = 0$ nie działa) zachodzi $\sum_{n \leq N} \mu(n) = O(N^{\frac{1}{2} + \varepsilon})$ (a więc, w jakimś sensie, ciekawi nas, czy μ zachowuje się jak losowy ciąg znaków), to otrzymalibyśmy dowód hipotezy Riemanna (tak naprawdę powyższy warunek prędkości zbieżności jest równoważny hipotezie Riemanna).

W świetle ostatniego punktu zrozumienie asymptotyki funkcji μ jest jednym z największych wyzwań matematyki. Naturalną kolejną rzeczą jest studiowanie trochę prostszego obiektu, mianowicie kwadratu funkcji Möbiusa μ^2 . Zauważmy, że $\mu^2 \in \{0, 1\}^{\mathbb{Z}}$ oraz $\mu^2(n) = 1$ wtedy i tylko wtedy, gdy n jest bezkwadratowa, co motywuje badanie zbioru liczb bezkwadratowych, $\mathcal{F}_{\mu^2} = \{n \in \mathbb{Z} \mid \mu^2(n) = 1\}$. Zbiory tej postaci były już rozpatrywane, z punktu widzenia teorii liczb, w latach 30 ub. wieku przez Besicovitcha, Erdösa, Chowla i innych. Podejście dynamiczne zostało zapoczątkowane przez P. Sarnaka w jego nowatorskich wykładach [51] o losowości funkcji Möbiusa. Mówiąc dokładniej, Sarnak analizował podshift wyznaczony przez μ^2 ,

$$\mathcal{X}_{\eta} = \overline{\{S^n \eta \mid n \in \mathbb{Z}\}} \subset \{0, 1\}^{\mathbb{Z}}, \quad (5.5)$$

gdzie $\eta = \mathbb{1}_{\mathcal{F}_{\mu^2}} \in \{0, 1\}^{\mathbb{Z}}$ jest funkcją charakterystyczną zbioru liczb bezkwadratowych. Krótko mówiąc, kodujemy zbiór \mathcal{F}_{μ^2} funkcją η i rozpatrujemy najmniejszy podzbiór S -niezmienniczy \mathcal{X}_{η} zawierający η . Można łatwo rozszerzyć tę konstrukcję do następującej: startujemy z podzbioru liczb naturalnych $\mathcal{B} \subset \mathbb{N} \setminus \{1\}$ i określamy *zbiór liczb \mathcal{B} -wolnych* $\mathcal{F}_{\mathcal{B}} = \mathbb{Z} \setminus \bigcup_{b \in \mathcal{B}} b\mathbb{Z}$, który następnie wyrażamy w $\{0, 1\}^{\mathbb{Z}}$, używając $\eta = \mathbb{1}_{\mathcal{F}_{\mathcal{B}}}$ (oczywiście $\mathcal{F}_{\mathcal{P}^2} = \mathcal{F}_{\mu^2}$, gdzie \mathcal{P}^2 jest zbiorem kwadratów liczb pierwszych). Podshift \mathcal{B} -wolny \mathcal{X}_{η} jest następnie dany przez (5.5).

Powiedzmy teraz kilka słów o ogólnych podshiftach \mathcal{B} -wolnych \mathcal{X}_{η} . Dla prostoty ograniczymy się do tzw. przypadku Erdösa, w którym zbiór \mathcal{B} składa się z liczb parami względnie pierwszych oraz szereg ich odwrotności jest zbieżny, $\sum_{b \in \mathcal{B}} 1/b < \infty$ (zauważmy, że to obejmuje przypadek bezkwadratowy). Dodajmy, że przy tych założeniach podshift \mathcal{X}_{η} jest *dziedziczny*, tzn. jest on zamknięty na zastępowanie jedynek przez zera na dowolnej współrzędnej punktu $\mathbf{x} \in \mathcal{X}_{\eta}$. Ponadto η jest punktem generującym dla *miary Mirsky'ego* $\nu_{\eta} \in \mathcal{M}_{\mathcal{X}_{\eta}}$. Innymi słowy,

$$\frac{1}{n} \sum_{i=1}^n \delta_{S^i \eta} \Rightarrow \nu_{\eta}. \quad (5.6)$$

Niech $\mathbf{Y} \sim \nu_\eta$. Intuicyjnie, (5.6) oznacza, że ν_η **liczy frekwencję bloków** pojawiających się na η . Dla przykładu $\nu_\eta(1) = \mathbb{P}(Y_0 = 1) = \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{\eta_i=1}$. Oprócz naturalności tej definicji okazuje się ponadto, że ν_η ma wiele interesujących własności. Po pierwsze podshift \mathbf{Y} jest ergodyczny oraz $\mathbf{H}(\mathbf{Y}) = 0$. Po drugie \mathbf{Y} ma **największą gęstość jedynek** pośród wszystkich procesów stacjonarnych na \mathcal{X}_η , tzn. $\mathbb{P}(Y_0 = 1) = \sup_{\mathbf{X} \in \mathcal{M}_{\mathcal{X}_\eta}} \mathbb{P}(X_0 = 1)$. Ponadto **miara o maksymalnej entropii** dla \mathcal{X}_η jest jedyna i jest ona dana przez $\mathbf{B} \cdot \mathbf{Y}$, gdzie \mathbf{B} jest i.i.d. $\mathbb{P}(B_0 = 0) = 1 - \mathbb{P}(B_0 = 1) = 1/2$ oraz $\mathbf{B} \perp \mathbf{Y}$. W końcu miara Mirsky’ego wyjaśnia strukturę elementów w $\mathcal{M}_{\mathcal{X}_\eta}$. Mówiąc dokładniej, okazuje się, że każdy proces stacjonarny $\mathbf{Z} \in \mathcal{X}_\eta$ (tzn. jego rozkład) jest postaci $\mathbf{X} \cdot \mathbf{Y}$ dla pewnego procesu $\mathbf{X} \in \mathcal{M}_{\{0,1\}^{\mathbb{Z}}}$ takiego, że (\mathbf{X}, \mathbf{Y}) jest stacjonarny.

Jednym z otwartych pytań zadanych przez Sarnaka był problem wewnętrznej ergodyczności układu bezkwadratowego. Problem ten został (pozytywnie) rozwiązany przez Pecknera w [46] i następnie rozwiązany w przypadku ogólnym w [33, 19]. Powstało naturalne pytanie, czy miara o maksymalnej entropii ma własność Gibbsa (jest tak w wielu naturalnych sytuacjach, wspomnijmy przypadek układów soficznych [58], tzn. faktorów topologicznych łańcuchów Markowa). Odpowiedź na to pytanie okazała się negatywna w przypadku bezkwadratowym (Peckner w [46]), co było pewną niespodzianką. Dowód Pecknera używał nietrywialnych faktów teorio-liczbowych dotyczących liczb pierwszych (i bazował na dokładnym wzorze liczącym miarę Mirsky’ego danego bloku) i z tego powodu zapytał on, czy jego rezultat rozszerza się na wszystkie układy \mathcal{B} -wolne. Nasz główny rezultat daje odpowiedź pozytywną na pytanie Pecknera. W rzeczywistości, prezentujemy ogólniejsze kryterium (stosowalne poza światem układów \mathcal{B} -wolnych), bazujące na pojęciach entropii topologicznej i gęstości (topologicznej) jedynek, i które gwarantuje brak własności Gibbsa (patrz twierdzenie 6.1). Warto wspomnieć, że uogólniając nasze argumenty, autorzy w [37] uzyskali ostatnio (grudzień 2020) rozszerzenie naszego rezultatu do klasy (niezerowych) potencjałów spełniających pewne zależności arytmetyczne.

Wprowadźmy teraz kilka pojęć pomocniczych. Niech \mathcal{X} będzie dowolnym podshiftem. Wówczas, dla dowolnego $\mathbf{X} \in \mathcal{M}_{\mathcal{X}}$, określamy

$$\mathbf{D} = \mathbf{D}_{\mathcal{X}} = \lim_{n \rightarrow \infty} \frac{1}{n} \max_{W \in \mathcal{L}^{(n)}} \#_1 W, \quad \mathbf{D}_{\mathbf{X}} = \lim_{n \rightarrow \infty} \frac{1}{n} \max_{W \in \mathcal{L}^{(n)}, \mathbb{P}(X_{[1,n]} \in W) > 0} \#_1 W$$

oraz

$$\mathbf{d} = \mathbf{d}_{\mathcal{X}} = \sup_{\mathbf{X} \in \mathcal{M}_{\mathcal{X}}} \mathbb{P}(X_0 = 1), \quad \mathbf{d}_{\mathbf{X}} = \mathbb{P}(X_0 = 1).$$

Można pokazać, że $\mathbf{d}_{\mathbf{X}} \leq \mathbf{D}_{\mathbf{X}} \leq \mathbf{D} = \mathbf{d}$. W szczególności $\sup_{\mathbf{X} \in \mathcal{M}_{\mathcal{X}}} \mathbf{D}_{\mathbf{X}} = \mathbf{D}_{\mathcal{X}}$ (każda miara, która osiąga supremum, jest nazywana miarą **jedynkowo-wysyconą**) i każda miara o **maksymalnej gęstości jedynek** (tzn. każdy proces \mathbf{X} , który osiąga supremum w $\sup_{\mathbf{X} \in \mathcal{M}_{\mathcal{X}}} \mathbf{d}_{\mathbf{X}} = \mathbf{d}$) musi być jedynkowo-wysycony (stąd miara Mirsky’ego musi być jedynkowo-wysycona). Dalej, dla układów \mathcal{B} -wolnych, zawsze mamy $\mathbf{D}_{\mathcal{X}_\eta} = \mathbf{H}_{\mathcal{X}_\eta}$ (patrz Proposition K w [19]).

Powiemy, że podshift $\mathcal{X} \subset \mathcal{X}^{\mathbb{Z}} \subset \mathbb{R}^{\mathbb{Z}}$ ma **własność splotu moltiplikatywnego**, gdy istnieje proces stacjonarny $\mathbf{Y} \in \mathcal{M}_{\mathcal{X}}$ spełniający $\mathbf{H}(\mathbf{Y}) = 0$ i taki, że

$$\mathbf{Z} \in \mathcal{M}_{\mathcal{X}} \Leftrightarrow \mathbf{Z} = \mathbf{X} \cdot \mathbf{Y}, \quad \text{gdzie } (\mathbf{X}, \mathbf{Y}) \in \mathcal{M}_{\mathcal{X}^{\mathbb{Z}} \times \mathcal{X}}. \quad (5.7)$$

Jak już wspomnieliśmy wcześniej, klasa układów \mathcal{B} -wolnych ma tę własność. Aby zobaczyć inne przykłady, zauważmy, że jeśli weźmiemy stały proces $\mathbf{Y} = \mathbf{1}$, to jako wynik (5.7) otrzymamy pełny shift $\mathcal{X} = \mathcal{X}^{\mathbb{Z}}$. Ponadto, jeśli \mathcal{X} spełnia (5.7), to zasada wariacyjna dla ciśnienia topologicznego może być napisana jako

$$\mathcal{P}_{\mathcal{X}, \varphi} = \sup_{(\mathbf{X}, \mathbf{Y}) \in \mathcal{M}_{\mathcal{X}^{\mathbb{Z}} \times \mathcal{Y}^{\mathbb{Z}}}} [\mathbf{H}(\mathbf{X} \cdot \mathbf{Y}) + \mathbb{E}\varphi(\mathbf{X} \cdot \mathbf{Y})]. \quad (5.8)$$

W szczególności wszystkie twierdzenia związane z (5.8) mogą być bezpośrednio stosowane do układów \mathcal{B} -wolnych (poniżej, ze względu na zwiezłość, często omijamy formułowanie takich wniosków).

5.1 Ciśnienie topologiczne w przestrzeniach z własnością splotu moltiplikatywnego

W tej części podamy (częściową) odpowiedź na następujące pytanie:

4. Ile wynosi ciśnienie topologiczne układów dynamicznych spełniających (5.7)? Czy odpowiadające stany równowagi są jedyne?

Dokładniej mówiąc, mamy trzy rodzaje twierdzeń związanych z wzorami na ciśnienie topologiczne. Pierwszy rodzaj (twierdzenie 5.1) dotyczy przypadku, w którym φ zależy od tylko jednej współrzędnej. To jest oczywiście najprostsze możliwe rozszerzenie w porównaniu z przypadkiem entropii topologicznej. Drugi rezultat (twierdzenie 5.2) zachodzi dla (wystarczająco) lokalnych potencjałów procesów okresowych. W twierdzeniu 5.3 mamy do czynienia z dowolnym ciągłym potencjałem i procesami, które mogą być aproksymowane w pewien sposób procesami okresowymi. Przypadek, gdy sam proces graniczny jest okresowy, jest tu wykluczony – to jest istotne dla stosowalności naszych metod (zauważmy, że m oraz p w twierdzeniu 5.2 nie są całkiem dowolne). Oprócz powyższych faktów udowodnimy również jedyną stanów równowagi w przypadku potencjałów zależnych od jednej współrzędnej (twierdzenie 5.1).

Od teraz zakładamy, że $\mathcal{X} \subset \mathbb{R}$, $0 \in \mathcal{X}$ i że procesy oznaczane literą \mathbf{Y} są **binarne**, tzn. $\mathcal{Y} = \{0, 1\}$.

Twierdzenie 5.1 (Potencjał zależący od jednej współrzędnej). *Jeśli $\varphi: \mathcal{X} \rightarrow \mathbb{R}$ zależy tylko od jednej współrzędnej, to*

$$\sup_{(\mathbf{X}, \mathbf{Y}) \in \mathcal{M}_{\mathcal{X}^{\mathbb{Z}} \times \mathcal{Y}^{\mathbb{Z}}}} [\mathbf{H}(\mathbf{X} \cdot \mathbf{Y}) + \mathbb{E}\varphi(\mathbf{X} \cdot \mathbf{Y})] = (1-d)\varphi(0) + d \log_2 \left(\sum_{x \in \mathcal{X}} 2^{\varphi(x)} \right),$$

gdzie $d = \mathbb{P}(Y_0 = 1)$. Ponadto, jeśli \mathbf{X} osiąga powyższe supremum, to $\mathbf{X} \cdot \mathbf{Y} \sim \mathbf{G} \cdot \mathbf{Y}$, gdzie $\mathbf{G} \parallel \mathbf{Y}$, \mathbf{G} jest procesem i.i.d. oraz $\mathbb{P}(G_i = x)$ jest proporcjonalne do $2^{\varphi(x)}$ (więc G_i jest miarą Gibbsa stowarzyszoną z φ).

Zauważmy, że twierdzenie to rozszerza fakt wewnętrznej ergodyczności udziedziczeń układów \mathcal{B} -wolnych do przypadku, w którym potencjał zależy od jednej współrzędnej. Zupełnie niedawno autorzy już wspomnianej pracy [37] uzyskali troszkę słabszy wynik dla zbiorów \mathcal{B} zawierających 2.²

Dla danego podzbioru skończonego liczb rzeczywistych \mathcal{X} (zawierającego zero), ciągłego potencjału $\varphi: \mathcal{X}^{\mathbb{Z}} \rightarrow \mathbb{R}$ i procesu \mathbf{Y} , istnieje pewna naturalna operacja (nazywana **Y-podniesieniem (ang. upgrade) potencjału φ**)

$$\varphi \xrightarrow{\mathbf{Y}} \Phi: \mathcal{X}^{\mathbb{Z}} \rightarrow \mathbb{R}$$

konieczna dla sformułowania naszych rezultatów. Dla dowolnego ściśle rosnącego ciągu liczb całkowitych \mathbf{r} określamy $\varphi_{\mathbf{r}}$ poprzez

$$\varphi_{\mathbf{r}}(\mathbf{z}) = \varphi \left(\dots, 0^{r_{-1}-r_{-2}-1}, \underbrace{z_{-1}}_{r_{-1}\text{-coord.}}, 0^{r_0-r_{-1}-1}, \underbrace{z_0}_{r_0\text{-coord.}}, 0^{r_1-r_0-1}, \underbrace{z_1}_{r_1\text{-coord.}}, 0^{r_2-r_1-1}, \dots \right).$$

Następnie definiujemy Φ jako

$$\Phi = \mathbb{E}\varphi_{\mathbf{R}}, \tag{5.9}$$

gdzie \mathbb{E} oznacza całkę Bochnera.

Najpierw przedyskutujemy przypadek okresowy procesu \mathbf{Y} . Niech $p \in \mathbb{N}$ będzie **okresem** procesu \mathbf{Y} , tzn. najmniejszą liczbą naturalną taką, że $S^p \mathbf{Y} = \mathbf{Y}$. Zauważmy, że wówczas $m = \sum_{i=1}^p Y_i$ jest równa **liczbie jedynek zawartych w okresie**.

Twierdzenie 5.2 (przypadek okresowy). *Niech p będzie okresem procesu \mathbf{Y} . Jeśli $\varphi: \mathcal{X}^{\mathbb{Z}} \rightarrow \mathbb{R}$ zależy od co najwyżej p kolejnych współrzędnych, to*

$$\sup_{(\mathbf{X}, \mathbf{Y}) \in \mathcal{M}_{\mathcal{X}^{\mathbb{Z}} \times \{0,1\}^{\mathbb{Z}}}} [\mathbf{H}(\mathbf{X} \cdot \mathbf{Y}) + \mathbb{E}\varphi(\mathbf{X} \cdot \mathbf{Y})] = \frac{1}{p} \log_2 \left[\sum_{z_{[0,m-1]} \in \mathcal{X}^m} 2^{p\Phi(z_{[0,m-1]})} \right],$$

gdzie $m = \sum_{i=1}^p Y_i$ oraz $\varphi \xrightarrow{\mathbf{Y}} \Phi$.

²Na pierwszy rzut oka ich twierdzenie 1.2 wydaje się silniejsze. Jednak jeśli rozpiszemy zasadę wariacyjną i użyjemy założenia $2 \in \mathcal{B}$, to natychmiastowo widzimy, że przypadek rozpatrywany w [37] redukuje się do potencjałów zależnych od jednej współrzędnej, a \mathcal{B} nadal musi zawierać 2.

Twierdzenie 5.2 prowadzi do następującego rezultatu:

Twierdzenie 5.3 (słabe granice układów okresowych). *Załóżmy, że $(\mathbf{Y}^{(n)})_n$ jest ciągiem okresowych procesów binarnych zbiegającym słabo do \mathbf{Y} . Niech p_n oznacza okres procesu $\mathbf{Y}^{(n)}$. Jeśli $\sum_{i=1}^{p_n} Y_i^{(n)} \xrightarrow{n \rightarrow \infty} \infty$, to dla dowolnego ciągłego potencjału $\varphi: \mathcal{X}^{\mathbb{Z}} \rightarrow \mathbb{R}$ mamy*

$$\sup_{(\mathbf{X}, \mathbf{Y}_n) \in \mathcal{M}_{\mathcal{X}^{\mathbb{Z}} \times \{0,1\}^{\mathbb{Z}}}} [\mathbf{H}(\mathbf{X} \cdot \mathbf{Y}) + \mathbb{E}\varphi(\mathbf{X} \cdot \mathbf{Y})] \xrightarrow{n \rightarrow \infty} \mathbb{P}(Y_0 = 1) \log |\mathcal{X}| + \sup_{\mathbf{z} \in \mathcal{X}^{\mathbb{Z}}} \Phi(\mathbf{z}),$$

gdzie $\varphi \xrightarrow{\mathbf{Y}} \Phi$.

Powyższe twierdzenie pozwala nam na otrzymanie następującego wniosku, który podaje dokładny wzór na ciśnienie topologiczne (udzielnictwa) układu \mathcal{B} -wolnego.

Twierdzenie 5.4. *Dla dowolnego układu \mathcal{B} -wolnego \mathcal{X}_η takiego, że odpowiadająca miara Mirsky'ego $\mathbf{Y} \sim \nu_\eta$ nie jest okresowa, i dowolnego ciągłego potencjału $\varphi: \{0,1\}^{\mathbb{Z}} \rightarrow \mathbb{R}$ mamy*

$$\mathcal{P}_{\widetilde{\mathcal{X}}_\eta, \varphi} = \mathbb{P}(Y_0 = 1) + \sup_{\mathbf{z} \in \mathcal{X}^{\mathbb{Z}}} \Phi(\mathbf{z}), \quad (5.10)$$

gdzie $\varphi \xrightarrow{\mathbf{Y}} \Phi$.

6 Układy \mathcal{B} -wolne

Na koniec opiszemy pozostałe rezultaty dotyczące układów \mathcal{B} -wolnych. Przypomnijmy, że podshift (\mathcal{X}, S) , gdzie $\mathcal{X} \subset \{0,1\}^{\mathbb{Z}}$, jest **dziedziczny**, jeśli dla każdego słowa $W \in \mathcal{L}$ oraz $W' \leq W$ mamy $W' \in \mathcal{L}$, gdzie $\mathcal{L} = \mathcal{L}_{\mathcal{X}}$ oznacza język podshiftu \mathcal{X} (zbiór wszystkich skończonych słów pojawiających się w \mathcal{X}). Ponadto, dla danego podshiftu $\mathcal{X} \subset \{0,1\}^{\mathbb{Z}}$, **udzielnictwo** podshiftu \mathcal{X} jest zdefiniowane jako

$$\widetilde{\mathcal{X}} = \{\mathbf{z} \in \{0,1\}^{\mathbb{Z}} : \mathbf{z} \leq \mathbf{x} \text{ dla pewnego } \mathbf{x} \in \mathcal{X}\}.$$

Niech \mathbf{B} oznacza symetryczny, i.i.d. proces binarny, zatem $\mathbb{P}(B_i = 0) = \mathbb{P}(B_i = 1) = 1/2$. Nasz główny rezultat jest następujący:

Twierdzenie 6.1. *Ustalmy podshift (\mathcal{X}, S) , gdzie $\mathcal{X} \subset \{0,1\}^{\mathbb{Z}}$, i załóżmy, że proces $\mathbf{Y} \in \mathcal{M}_{\mathcal{X}}^c$ jest jedyńkowo-wysycony i bezatomowy. Jeśli $D_{\widetilde{\mathcal{X}}} = \mathbf{H}_{\widetilde{\mathcal{X}}}$ oraz $\mathbf{Y} \perp \mathbf{B}$, to $\mathbf{B} \cdot \mathbf{Y}$ nie ma własności Gibbsa.*

Twierdzenie 6.1 natychmiast przynosi pozytywną odpowiedź na pytanie Pecknera z pracy [46].

Wniosek 6.2. *Niech $\mathcal{B} \subset \mathbb{N} \setminus \{1\}$. Załóżmy, że miara Mirsky'ego ν_η nie jest okresowa. Wówczas miara o maksymalnej entropii podshiftu $(\widetilde{\mathcal{X}}_\eta, S)$ nie ma własności Gibbsa.*

Jak już wspomnieliśmy, ten wniosek został nieco rozszerzony (do przypadku pewnych punktów równowagi) w pracy [37].

Twierdzenie 6.1 stosuje się poza światem układów \mathcal{B} -wolnych. Przypomnijmy, że podshift \mathcal{X} nazywa się **monoergodyczny**, gdy posiada on dokładnie jedną (stąd ergodyczną) miarę niezmienniczą (ze względu na shift).

Wniosek 6.3. *Jeśli (\mathcal{X}, S) , gdzie $\mathcal{X} \subset \{0,1\}^{\mathbb{Z}}$, \mathbf{Y} jest jedyną miarą ergodyczną miara oraz $\mathbf{H}_{\mathcal{X}} = 0$, to $\mathbf{B} \cdot \mathbf{Y}$ nie ma własności Gibbsa, jeśli tylko \mathbf{Y} jest bezatomowa.*

Wniosek 6.4. *Jeśli $(\widetilde{\mathcal{X}}, S)$ jest dziedzicznym układem Sturmia, to jego miara o maksymalnej entropii nie ma własności Gibbsa.*

Jako pewien „produkt uboczny” naszych rozważań w rozprawie udowodniono kilka nowych rezultatów, wzbogacających wiedzę o samych układach \mathcal{B} -wolnych. W szczególności, udowodniono twierdzenie odwrotne do niedawnego rezultatu Kellera [31], otrzymując charakteryzację dynamiczną ważnej własności arytmetycznej naprężenia (ang. tautness) podzbioru liczb całkowitych (z grubsza, naprężenie oznacza, że każdy element zbioru \mathcal{B} odgrywa nietrywialną rolę w zbiorze wielokrotności z punktu widzenia gęstości).

Twierdzenie 6.5. *Niech $\mathcal{B} \subset \mathbb{N} \setminus \{1\}$. Jeśli odpowiadająca miara Mirsky'ego ν_η ma pełny nośnik topologiczny \mathcal{X}_η , to zbiór \mathcal{B} jest naprężony.*

References

- [1] J. Aaronson, D. Gilat, and M. Keane. On the structure of 1-dependent Markov chains. *Journal of Theoretical Probability*, 5(3):545–561, 1992.
- [2] R. Adamczak. A tail inequality for suprema of unbounded empirical processes with applications to Markov chains. *Electron. J. Probab.*, 13:no. 34, 1000–1034, 2008.
- [3] R. Adamczak and W. Bednorz. Exponential concentration inequalities for additive functionals of Markov chains. *ESAIM Probab. Stat.*, 19:440–481, 2015.
- [4] L. Arnold, V. M. Gundlach, and L. Demetrius. Evolutionary formalism for products of positive random matrices. *The Annals of Applied Probability*, pages 859–901, 1994.
- [5] P. Bertail and G. Ciołek. New Bernstein and Hoeffding type inequalities for regenerative Markov chains. *ALEA Lat. Am. J. Probab. Math. Stat.*, 16(1):259–277, 2019.
- [6] P. Bertail and S. Cléménçon. Regenerative block bootstrap for Markov chains. *Bernoulli*, 12(4):689–712, 2006.
- [7] R. Bowen. Equilibrium states and the ergodic theory of anosov diffeomorphisms. *Springer Lecture Notes in Math*, 470:78–104, 1975.
- [8] R. Bowen. *Equilibrium states and the ergodic theory of Anosov diffeomorphisms*, volume 470 of *Lecture Notes in Mathematics*. Springer-Verlag, Berlin, revised edition, 2008. With a preface by David Ruelle, Edited by Jean-René Chazottes.
- [9] M. Burr, S. Das, C. Wolf, and Y. Yang. Computability of topological pressure on compact shift spaces beyond finite type. *arXiv preprint arXiv:2010.14686*, 2020.
- [10] R. M. Burton, M. Denker, and M. Smorodinsky. Finite state bilaterally deterministic strongly mixing processes. *Israel Journal of Mathematics*, 95(1):115–133, 1996.
- [11] X. Chen. Limit theorems for functionals of ergodic Markov chains with general state space. *Mem. Amer. Math. Soc.*, 139(664):xiv+203, 1999.
- [12] S. J. M. Cléménçon. Moment and probability inequalities for sums of bounded additive functionals of regular Markov chains via the Nummelin splitting technique. *Statist. Probab. Lett.*, 55(3):227–238, 2001.
- [13] V. De Valk. Hilbert space representations of m-dependent processes. *The Annals of Probability*, pages 1550–1570, 1993.
- [14] J. Dedecker and S. Gouëzel. Subgaussian concentration inequalities for geometrically ergodic Markov chains. *Electron. Commun. Probab.*, 20:no. 64, 12, 2015.
- [15] L. Demetrius and C. Wolf. Evolutionary entropy and the second law of thermodynamics. *arXiv preprint arXiv:2005.10332*, 2020.
- [16] L. A. Demetrius. Boltzmann, Darwin and directionality theory. *Physics reports*, 530(1):1–85, 2013.
- [17] L. A. Demetrius and V. M. Gundlach. Directionality theory and the entropic principle of natural selection. *Entropy*, 16(10):5428–5522, 2014.
- [18] R. Douc, A. Guillin, and E. Moulines. Bounds on regeneration times and limit theorems for subgeometric Markov chains. *Ann. Inst. Henri Poincaré Probab. Stat.*, 44(2):239–257, 2008.
- [19] A. Dymek, S. Kasjan, J. Kułaga-Przymus, and M. Lemańczyk. \mathcal{B} -free sets and dynamics. *Trans. Amer. Math. Soc.*, 370:5425–5489, 2018.
- [20] N. A. Friedman and D. Ornstein. On isomorphism of weak Bernoulli transformations. *Advances in mathematics*, 5(3):365–394, 1970.
- [21] H. Furstenberg. Disjointness in ergodic theory, minimal sets, and a problem in Diophantine approximation. *Math. Systems Theory*, 1:1–49, 1967.
- [22] H. Furstenberg, Y. Peres, and B. Weiss. Perfect filtering and double disjointness. In *Annales de l’IHP Probabilités et statistiques*, volume 31, pages 453–465, 1995.
- [23] F. Gao, A. Guillin, and L. Wu. Bernstein-type concentration inequalities for symmetric Markov processes. *Theory Probab. Appl.*, 58(3):358–382, 2014.
- [24] R. Garbit. A note on Furstenberg’s filtering problem. *Israel J. Math.*, 182:333–336, 2011.

- [25] H.-O. Georgii. *Gibbs measures and phase transitions*, volume 9. Walter de Gruyter, 2011.
- [26] E. Glasner. *Ergodic theory via joinings*. American Mathematical Soc., 2003.
- [27] A. Holroyd and T. Liggett. Finitely dependent coloring. *Forum of Mathematics, Pi*, 4, 02 2014.
- [28] B. Jiang, Q. Sun, and J. Fan. Bernstein’s inequality for general Markov chains. *arXiv preprint arXiv:1805.10721*, 2018.
- [29] A. Katok. Fifty years of entropy in dynamics: 1958–2007. *Journal of Modern Dynamics*, 1(4):545, 2007.
- [30] G. Keller. *Equilibrium states in ergodic theory*, volume 42. Cambridge university press, 1998.
- [31] G. Keller. Tautness of sets of multiples and applications to \mathcal{B} -free systems. *Studia Math.*, 247(2):205–216, 2019.
- [32] A. Kłopotowski and J. B. Robertson. Some new examples of pairwise independent random variables. *Sankhyā: The Indian Journal of Statistics, Series A*, pages 72–88, 1999.
- [33] J. Kułaga-Przymus, M. Lemańczyk, and B. Weiss. On invariant measures for \mathcal{B} -free systems. *Proc. Lond. Math. Soc. (3)*, 110(6):1435–1474, 2015.
- [34] O. E. Lanford. Entropy and equilibrium states in classical statistical mechanics. *Lecture Notes in Physics*, pages 1–113, 1975.
- [35] P. Lezaud. Chernoff-type bound for finite Markov chains. *Ann. Appl. Probab.*, 8(3):849–867, 1998.
- [36] P. Lezaud. Chernoff and Berry-Esséen inequalities for Markov processes. *ESAIM Probab. Statist.*, 5:183–201, 2001.
- [37] Z. Lin and E. Chen. Equilibrium states which are not gibbs measure on hereditary subshifts. *arXiv preprint arXiv:2012.03409*, 2020.
- [38] F. Matúš. On two–block–factor sequences and one–dependence. *Proceedings of the American Mathematical Society*, 124(4):1237–1242, 1996.
- [39] R. D. Mauldin, M. Urbanski, and M. Urbański. *Graph directed Markov systems: geometry and dynamics of limit sets*, volume 148. Cambridge University Press, 2003.
- [40] F. Merlevède, M. Peligrad, and E. Rio. *High dimensional probability V: the Luminy volume*, volume 5. Institute of Mathematical Statistics, Beachwood, OH, 2009. Including papers from the 5th International Conference (HDP V) held in Luminy, May 26–30, 2008.
- [41] F. Merlevède, M. Peligrad, and E. Rio. A Bernstein type inequality and moderate deviations for weakly dependent sequences. *Probab. Theory Related Fields*, 151(3-4):435–474, 2011.
- [42] F. Merlevède and E. Rio. Strong approximation for additive functionals of geometrically ergodic Markov chains. *Electronic Journal of Probability*, 20, 2015.
- [43] S. P. Meyn and R. L. Tweedie. *Markov chains and stochastic stability*. Communications and Control Engineering Series. Springer-Verlag London, Ltd., London, 1993.
- [44] E. Nummelin. *General irreducible Markov chains and nonnegative operators*, volume 83 of *Cambridge Tracts in Mathematics*. Cambridge University Press, Cambridge, 1984.
- [45] D. Paulin. Concentration inequalities for Markov chains by Marton couplings and spectral methods. *Electron. J. Probab.*, 20:no. 79, 32, 2015.
- [46] R. Peckner. Uniqueness of the measure of maximal entropy for the squarefree flow. *Israel J. Math.*, 210(1):335–357, 2015.
- [47] Y. B. Pesin. *Dimension theory in dynamical systems: contemporary views and applications*. University of Chicago Press, 2008.
- [48] D. Ruelle. *Statistical mechanics*. The Mathematical Gazette, 1999. Rigorous results, Reprint of the 1989 edition.
- [49] D. Ruelle. *Thermodynamic formalism: the mathematical structure of equilibrium statistical mechanics*. Cambridge University Press, 2004.
- [50] P.-M. Samson. Concentration of measure inequalities for Markov chains and Φ -mixing processes. *The Annals of Probability*, 28(1):416–461, 2000.
- [51] P. Sarnak. Three lectures on the Möbius function, randomness and dynamics. unpublished, 2010.

- [52] P. C. Shields. *The ergodic theory of discrete sample paths*, volume 13. American Mathematical Soc., 1996.
- [53] J. G. Sinaĭ. Gibbs measures in ergodic theory. *Uspehi Mat. Nauk*, 27(4(166)):21–64, 1972.
- [54] J. T. Trevors and M. H. Saier Jr. Thermodynamic perspectives on genetic instructions, the laws of biology and diseased states. *Comptes rendus biologies*, 334(1):1–5, 2011.
- [55] R. Vershynin. *High-dimensional probability: An introduction with applications in data science*, volume 47. Cambridge university press, 2018.
- [56] P. Walters. Some results on the classification of non-invertible measure preserving transformations. In *Recent Advances in Topological Dynamics*, pages 266–276. Springer, 1973.
- [57] P. Walters. A variational principle for the pressure of continuous transformations. *American Journal of Mathematics*, 97(4):937–971, 1975.
- [58] B. Weiss. Subshifts of finite type and sofic systems. *Monatsh. Math.*, 77:462–474, 1973.
- [59] O. Wintenberger. Deviation inequalities for sums of weakly dependent time series. *Electron. Commun. Probab.*, 15:489–503, 2010.