

# Odwzorowanie logistyczne

K. K.\*, P. S.†, M. B.‡

20 listopada 2020

## Spis treści

1	Wstęp	2
2	Cel pracy	2
3	Odwzorowania logistyczne - zastosowanie	3
4	Parę słów o programie	3
5	Podgląd wyników	4
6	Podsumowanie	8
7	Bibliografia	8
8	Appendix	9

---

\*Politechnika Krakowska im. Tadeusza Kościuszki w Krakowie

†Politechnika Krakowska im. Tadeusza Kościuszki w Krakowie

‡Politechnika Krakowska im. Tadeusza Kościuszki w Krakowie

# 1 Wstęp

Odwzorowanie logistyczne stosowane jest do tworzenia modeli demograficznych. Spopularyzowane zostało w roku 1976 przez biologa Roberta Maya, jako model demograficzny w sposób analogiczny do równania logistycznego Pierre'a Fracois Verhulsta.

Zapis matematyczny odwzorowania logistycznego przedstawiamy w następujący sposób:

$$X(N+1) = (kX_n)(1-X_n)$$

W tym równaniu  $x_n$  jest liczbą w przedziale  $(0,1)$  jako reprezentacja stosunku istniejącej populacji do jej maksymalnej wartości. Parametr  $k$  mieści się w przedziale  $(0,4)$ . To równanie nieliniowej różnicy ma na celu ukazanie dwóch efektów:

- Pierwszym jest efekt reprodukcji. Zachodzi kiedy populacja będzie rosnąć w proporcjonalnym tempie do jej obecnej ilości w przypadku kiedy jest ona niewielka.
- Drugim efektem jest wymieranie (zależne od gęstości). W przypadku tego efektu, tempo wzrostu będzie zmniejszać się proporcjonalnie do wartości uwzględnionej teoretycznym maksimum populacji pomniejszonej o jej aktualny stan.

# 2 Cel pracy

Głównym celem tej pracy jest przedstawienie pojęcia odwzorowania logicznego oraz zbadanie zależności od parametru  $k$  za pomocą algorytmów zaimplementowanych w języku Python.

### 3 Odwzorowania logistyczne - zastosowanie


Względna prostota odwzorowania logistycznego sprawia, że jest powszechnie używana jako punkt wyjścia do rozważań nad koncepcją chaosu. Z opisu dowiadujemy się, że systemy chaotyczne wykazują dużą wrażliwość na warunki początkowe (typową właściwość odwzorowania logistycznego dla większości  $k$  których wartości wahają się pomiędzy **3,57 a 4**). Częstym źródłem owych warunków jest to, że odwzorowanie przedstawia powtarzające się **zaginanie i rozciąganie przestrzeni**, na której jest zdefiniowana. To rozciąganie i zwijanie prowadzi nie tylko do stopniowej dywergencji sekwencji iteracji, ale także do wykładniczej dywergencji, której dowodem jest również złożoność i nieprzewidywalność chaotycznego odwzorowania logistycznego.

W rzeczywistości wykładnicza rozbieżność sekwencji iteracji wyjaśnia związek między chaosem a nieprzewidywalnością, czyli mały błąd stanu początkowego systemu, który będzie odpowiadał dużemu błędowi stanu późniejszego. **W związku z tym, prognozy dotyczące przyszłych stanów stają się stopniowo gorsze gdy istnieją nawet bardzo małe błędy w naszej wiedzy o stanie początkowym.** Ta cecha nieprzewidywalności i pozornej losowości sprawiła, że równanie odwzorowania logistycznego zostało **użyte jako generator liczb pseudolosowych we wczesnych komputerach oraz szyfrowaniu danych.**

Pomimo chaotycznej natury, możliwe jest sformułowanie precyzyjnych stwierdzeń dotyczących prawdopodobieństwa przyszłego stanu w tym systemie. Jeśli (prawdopodobnie chaotyczny) układ dynamiczny ma **atraktor** (może nim być punkt, zamknięta krzywa lub fraktal), istnieje wówczas miara prawdopodobieństwa, która określa długoterminową proporcję czasu spędzanego przez system w różnych obszarach atraktora. W przypadku odwzorowania logistycznego z parametrem  $k = 4$  i stanem początkowym w **(0,1)** atraktorem jest również przedział  $(0,1)$ , a miara prawdopodobieństwa odpowiada rozkładowi beta o parametrach  **$a = 0,5$  i  $b = 0,5$ .**

### 4 Parę słów o programie


Do rozwiązania problemu stworzyliśmy dwa trywialne skrypty w języku Python, z użyciem bibliotek PyQt5 oraz PyQtGraph.






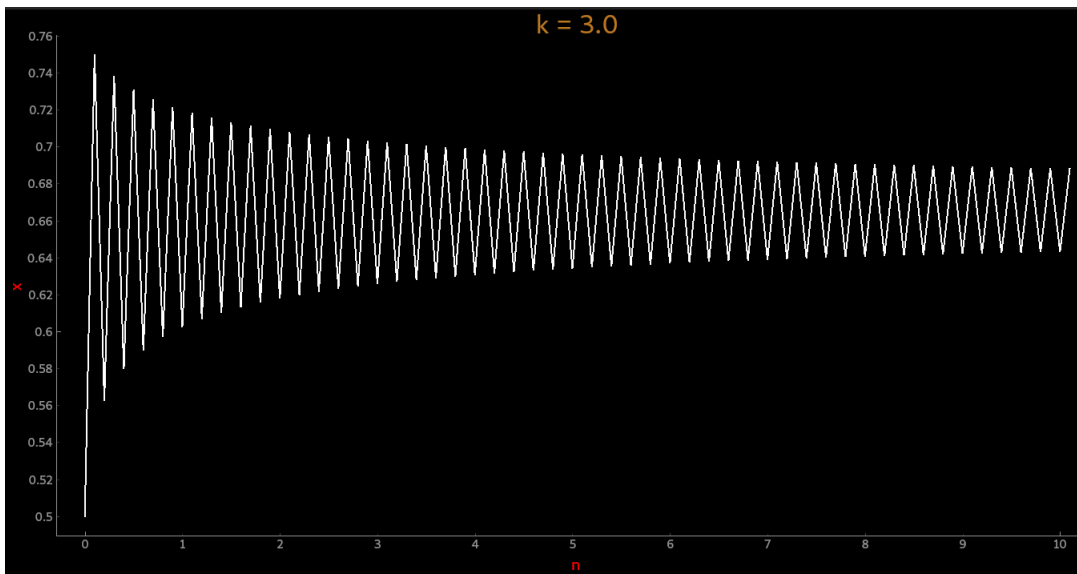
Rysunek 1: Diagram bifurkacyjny wygenerowany przez skrypt


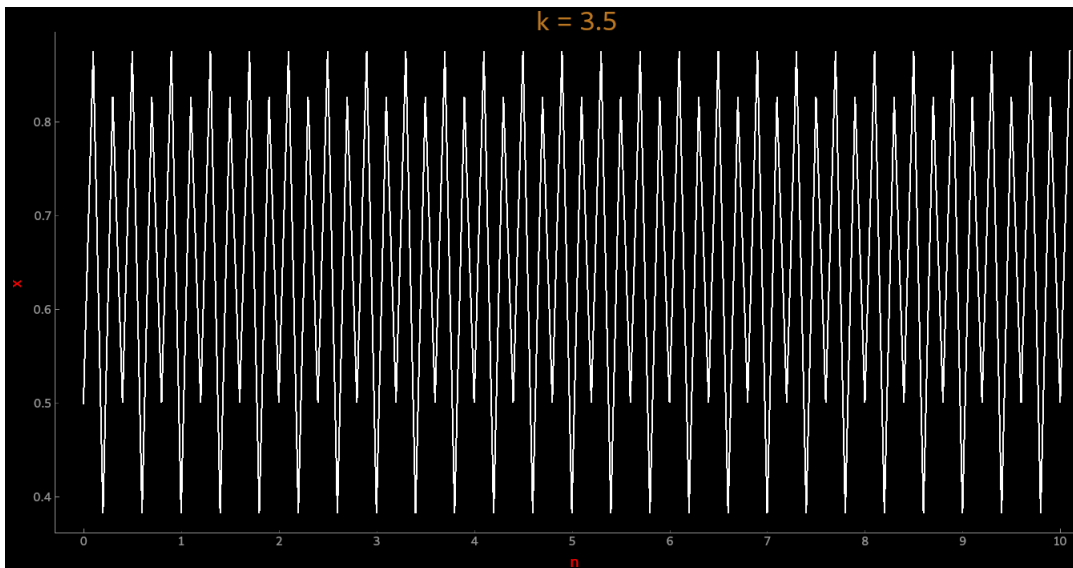
## 5 Podgląd wyników

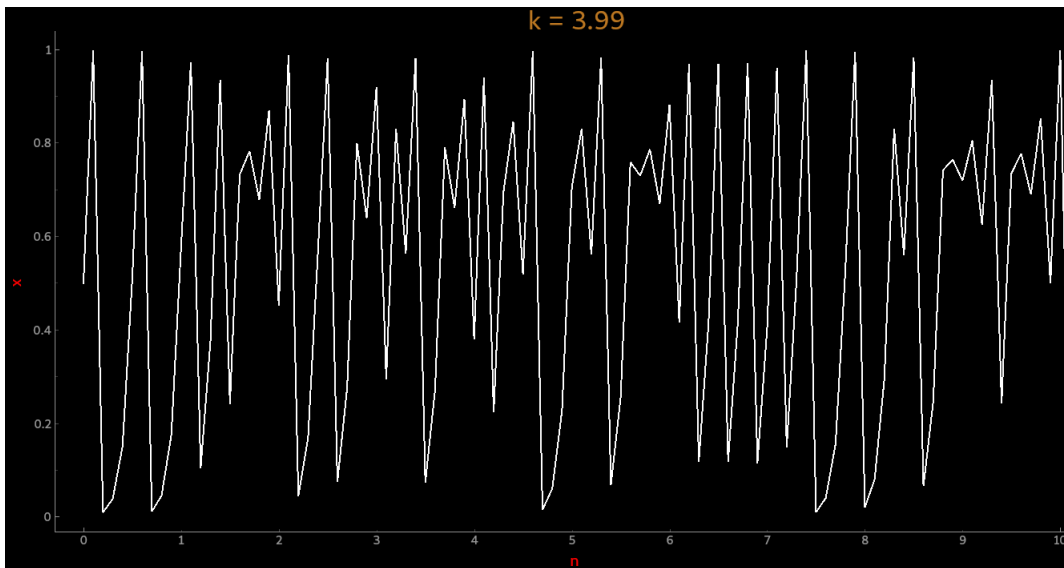
Przykładowe wykresy zależności  $x_n$  od generacji  $n$  dla  $x_0 = 0,5$











## 6 Podsumowanie

Programy zachowują się zgodnie z przewidywaniami, widać dużą wrażliwość na warunki początkowe. Widzimy, że współczynnik  $k$  odgrywa dużo większą rolę niż  $x_0$ .

## 7 Bibliografia

- [https://en.wikipedia.org/wiki/Logistic\\_map](https://en.wikipedia.org/wiki/Logistic_map)
- <https://pl.wikipedia.org/wiki/Atraktor>
- <https://www.youtube.com/watch?v=ovJcsL7vyrk>
- <https://geoffboeing.com/2015/03/chaos-theory-logistic-map>



## 8 Appendix

Wykresy dla  $x_0 = 0.1$ .

