
Przyrostowe uczenie się klasyfikatorów ze zmiennych i niezbalansowanych strumieni danych



Jerzy Stefanowski

Instytut Informatyki
Politechnika Poznańska

KI PAN, 11 maja 2022

Plan seminarium

1. Klasyfikacja nadzorowana i złożone dane
2. Strumienie danych
 - Charakterystyka
 - Sposoby przetwarzania strumieni
3. Zmienna definicja pojęć (ang. concept drift)
4. Algorytmy uczenie zespołów klasyfikatorów (AUE)
5. Niezbalansowanie rozkładu klas
 - Niezbalansowane strumienie
 - Miary oceny
 - Analiza wpływu czynników trudności danych oraz zmian

Klasyfikacja nadzorowana

- Dane uczące S – przykłady $\mathbf{x}$ opisane atrybutami A oraz etykietowane (ang. target value) y

- należące do dwóch lub więcej K klas

$$S = \left\{ (\mathbf{x}_i, c_i) \mid \mathbf{x}_i \in A^p, c_i \in \{C_1, \dots, C_k\} \right\}_{i=1}^N$$

- Różne reprezentacje:

- Ten wykład - tabela atrybut-wartość DT = (X, AUC)

- Uczenie się $\rightarrow$ odkryć zależność między A and y (klasa C)

$$y_i = f(\mathbf{x}_i) = c_i$$

- Dążymy do minimalizacji funkcji straty $L(y_i, c_i) + \sigma$

- Bardzo wiele zaproponowanych algorytmów

- **Big Data – nie tylko masywne, inne V's**

Velocity - czas, prędkość i zmienność

- Dane-generowane z dużą szybkością i wymagają odpowiednio szybkiego przetwarzania
- Spóźnione decyzje → nieakceptowane straty
- Przykłady
 - e-marketing → oferty we właściwym czasie
 - Monitorowanie stanu zdrowia
 - Analiza ruchu sieciowego
 - Wykrywanie defraudacji, zagrożeń
- Tryb dostępu i przetwarzania „online”
- Wiele zastosowań → **strumienie danych**
 - Przyrostowe i wydajne obliczeniowo przetwarzanie
 - Zmienność rozkładów danych

Potrzebne nowe algorytmy eksploracji strumieni danych !

Co to jest strumień danych?

- “A **data stream** is a potentially unbounded, ordered sequence of data items, which arrive continuously at high-speeds”

Springer Encyclopedia of Machine Learning

- “It is impossible to control the order in which items arrive, nor is it feasible to locally **store** a stream in its entirety”
- Struktura danych $\neq$ audio lub video data; także inna niż szeregi czasowe
- Dalsze rozważania – odpowiednik danych tabelarycznych

- Sieci sensorów
- Telemechanika (energetyka)
- Analiza użytkowników (WWW)
- Filtrowanie informacji lub wiadomości sieciowych
- Sterowanie obiektami przemysłowymi
- Inteligentne miasta i IoT (Internet przedmiotów)
- ...

Timestamp	Puis. A (kW)	Puis. R (kVAR)	U 1 (V)	I 1 (A)
...	...	...	...	...
16/12/2006-17:26	5,374	0,498	233,29	23
16/12/2006-17:27	5,388	0,502	233,74	23
16/12/2006-17:28	3,666	0,528	235,68	15,8
16/12/2006-17:29	3,52	0,522	235,02	15
...	...	...	...	...

Charakterystyka strumieni danych


- Źródła generują dane w postaci nieprzerwanego strumienia
 - Trudności z przechowywaniem wszystkich elementów danych
 - Konieczność przetwarzania szybkiego strumienia w ograniczonym czasie
 - Przyrostowe działanie algorytmów
- Gotowość modelu do natychmiastowej analizy i predykcji
- **Zmienność rozkładów danych → niestacjonarne środowiska**

	Statyczne	Strumień
No. odczytów	wielokrotne	pojedyncze
Czas	nie jest krytyczny	ograniczony
Uzycie PAO	b. elastyczne	ograniczone
Rezultaty	dokładne	przybliżone
Przetwarz. Rozproszone	zwykle nie	tak

Inne wyzwania niż tylko modele predykcyjne:

- Próbkowanie danych, tworzenie zastępczych reprezentacji (histogramy)
- Przyrostowe grupowanie danych (analiza skupień)
- Analiza zbiorów częstych, reguł asocjacyjnych, ...

Zmienne strumienie danych (concept drift)




Zmienność danych (w tym definicji klas) wraz z upływem czasu, **tzw. concept drift**

Zmiany te mają negatywny wpływ na trafność klasyfikacji

Klasyczne (statyczne) algorytmy modeli predykcyjnych nie mogą być stosowane!

Nowe wymagania do algorytmów – wydajne obliczeniowo + zdolności reakcji na zmiany



Rys: za D.Brzezinski

Przykłady zmienności w strumieniach

- Wykrywanie “niechcianych wiadomości”
 - “Old spam is not a new spam”
 - Twórcy spamu poszukują nowych rozwiązań
- Analizowanie preferencji klientów
- Filtrowanie informacji oraz systemy rekomendacyjne
 - Co to jest interesujący produkt (książka, muzyka)?
- Wykrywanie niewłaściwego zachowania się lub ataków sieciowych (ang. intruder detection)
- Zmienne rynki finansowe
- ...

Więcej: Indre Zliobaite, Mykola Pechenizkiy, and Joao Gama: An overview of concept drift applications. Chapter 4 in N.Japkowicz and J.Stefanowski (Eds) Big Data Analysis: New Algorithms for a New Society, Springer (2016).

Zmienność pojęć

Strumień S - sekwencja przykładów x_t ($t=1,2, \dots, T$)

→ Łączny rozkład prawdopodobieństwa $p^t(x,y)$ w chwili t

- Zmienność strumienia → dla czasu t oraz $t+\Delta$, istnieje x taki że $p^t(x,y) \neq p^{t+\Delta}(x,y)$
 - Różne składowe prawdopodobieństwa mogą podlegać zmianom
- **Real drift** (typowe dla klasyfikacji nadzorowanej)
 - posterior prob. klasy $p(y|x)$ zmienia się
- Virtual drift → zmiany w danych, np. $p(x)$, niewpływające na $p(y|x)$, także zmienne prawdopodobieństwa klas $p(y)$ mogą nie mieć wpływu na $p(y|x)$

Rodzaje zmian pojęć (concept drift)

Strumień $S = \langle S_1, S_2, S_3, \dots, S_n \rangle$, gdzie część S_i generowana przez źródło ze stacjonarnym rozkładem D_i

Dryf / zmiana $\rightarrow$ przejście między S_j i S_{j+1}



(Widmer $\rightarrow$ Hidden context of changes)

Różne typy zmian

- A **sudden** (abrupt) drift - S_j jest nagle zastąpione przez S_{j+1} ($D_j \neq D_{j+1}$)
- **Gradual** drifts - wolniejsze tempo zmiany
 - W strefie zmian wymieszane prawdopodobieństwa pojawiania się S_j oraz S_{j+1}
 - Incremental - sekwencja drobnych zmian
- **Reoccurring** concepts

Nie powinno się reagować na anomalie (blips)

oraz szum informacyjny w sekwencji (noise)



Więcej o zmienności pojęć

- Real concept drift
 - Pełny lub dotyczący części pojęć - sub-concept drifts
 - Drift severity (scope) - ograniczony do części $\text{Dom}(x)$ [Minku et al. 2010]
- Siła zmiany (ang. magnitude) → sposób oceny
 - Kullback-Leibler Divergence, Hellinger Distance and Total Variation Distance
- Identyfikacja punktów charakterystycznych
- Niejasności w detekcji tzw. gradual drifts
- Drift reoccurrence
 - Cyclical drifts - powtarzanie się pojęć w pewnej kolejności [Tsymbal 2004]; stałe albo zmienne okresy
 - Non-cyclical drifts
- Novel class appearance $p^t(y=C_l)=0$ for t and $p^{t+\Delta}(y=C_l)>0$




Recovery analysis – z różnych zmian

Różne rodzaje strumieni i ich przetwarzanie


Dostępność etykiet przykładów Sposób przetwarzania

- Pełne i natychmiastowe
- Opóźnienie dostępu do etykiet (ang. delayed labelling)
- Częściowo nadzorowane (etykiety dostępne co pewien czas)
- Wstępnie etykietowane (ang. unsupervised / extreme labelling)

- Blokowy (ang. chunk)




- Online – przykład po przykładzie




- Hybrydowo

Wpływ na ocenę modeli

- Przyrostowo lub Prequential




Podział algorytmów z uwagi na dostos. do zmian



Bifet A., Gama. J., Pechenizky M., Zliobaite I.: Handling concept drift. Importance, challenges and solutions. PAKDD Tutorial (2011)

Triggers - detektory dryfu pojęcia



Inspiracje statystycznej kontroli procesów

DDM, EDDN, EWMA,...

Sekwencje i testy

Cumulative Sum Test, Page-Hinkley test

Obserwacja zmian rozkładów w dwóch oknach przesuwnych

ADWIN + podejścia nienadzorowane

Analiza zmian modeli - np. rozkładów w drzewie, lub zespole modeli


Więcej: J.Gama, I.Zliobaite, M.Pechenizkiy, A. Bouchachia: A Survey on Concept Drift Adaptation. ACM Compt. 2013 i późniejsze teksty Geoff Webb

Wykorzystanie zespołów klasyfikatorów (ensembles) do zmiennych strumieni

- Wiele propozycji dla statycznych danych
- Dogodne dla zmiennych strumieni


Stability-plasticity
dilemma

- Modularna konstrukcja
 - Uwzględnianie nowych danych
 - dodanie nowego składnika (modelu)
 - przyrostowe uaktualnianie
 - Naturalne zapominanie
 - pruning ensembles; sliding windows
 - Ciągła aktualizacja agregacji modeli (voting weights)
 - Redukcja wariancji w błędzie zespołu w odniesieniu do pojedynczego modelu
 - stabilność




Zmiany rozkładów – każdy składnik zespołu może modelować różny fragment → łączenie poprzez odpowiednie ważenie predykcji i zapominanie

Accuracy Updated Ensemble - AUE




- Konstruuje okresowo nowy klasyfikator i zastępuje najgorszy w zespole, okresowo ocena składowych – **nieliniowe wagi** klasyfikatorów
- **Przyrostowo douczaj klasyfikatory**
 - Poprawia reakcję na zmiany oraz niezależność od wielkości bloku B_i
- **Analiza zmian poprzez wagowanie klasyfikatorów w zespole** i ocena wpływu nowo-wprowadzonego klasyfikatora $w_{ij} = \frac{1}{MSE_{ij} + MSE_r + \varepsilon}$
 - Efektywna czasowo realizacja
- Założenia - nowy klasyfikator potencjalnie najlepszy ($MSE_{ij}=0$) - otrzymuje najwyższą wartość wagi; usuwanie najgorszych w zespole

Reakcja klasyfikatorów na zmiany (dryf)



Classification accuracy on RBF_{GR} (slow, gradual changes)



Classification accuracy for $Tree_5$ dataset (fast, sudden)

Online Accuracy Updated Ensemble

- Przestanki do rozwiązań [Brzez. Stef ECMLPKDD 2012]
 - Przyrostowa aktualizacja klasyfikatora i ważenia ich głosów → najlepszy wpływ na poprawę predykcji
 - Konieczność efektywnej czasowo realizacji
- Główne elementy nowej propozycji (OAUE)
 - On-line klasyfikatory
 - Okresowe dodanie nowego klasyfikatora z największą wagą
 - Pamięć → sliding window
 - New weighting function → efektywna czasowo i obliczenia po każdym przykładzie



Więcej → D. Brzezinski, J. Stefanowski, 2014. Combining Block-based and Online Methods in Learning Ensembles from Concept Drifting Data Streams. Information Sciences, 265, 50-67.

Eksperymenty porównawcze

*Ranks in
Friedman test*

OAUE	1,93
Bag	2,73
DWM	2,80
Lev	2,80
ACE	4,73

Average prequential classification accuracy

Data	ACE	DWM	Lev	Bag	OAUE
Airlines	64,86	64,98	62,84	64,24	67,02
CovType	69,47	89,87	92,11	88,84	90,98
Hyp_F	84,34	89,94	88,49	89,54	90,43
Hyp_S	79,62	88,48	85,43	88,35	88,95
LED_M	46,45	53,34	51,31	53,33	53,40
LED_ND	39,80	51,48	49,98	51,50	51,48
PAKKDD	-	80,24	79,85	80,22	80,23
Poker	79,79	91,29	97,67	76,92	88,89
RBF_B	84,78	96,00	98,22	97,87	97,87
RBF_GR	84,16	95,49	97,79	97,54	97,42
SEA_G	85,97	88,39	89,00	88,36	88,83
SEA_S	85,98	89,15	89,26	88,94	89,33
Tree_SR	43,39	42,48	47,88	48,77	46,04
Wave	-	84,02	83,99	85,51	85,50
Wave_M	-	83,76	83,46	84,95	84,90


	ACE	DWM	Lev	Bag	OAUE
Memory	--	1.81	3.56	2.6	2.0
Time	2.5	1.81	4.81	3.2	2.6

*Ranks in
Friedman test*

Niezbalansowane strumienie danych

Niezbalansowanie klas (ang. class imbalance)

- Intensywne badania dla danych statycznych
→ wiele propozycji poprawy klasyfikatorów (data vs. algorithmic modifications)
- Większość propozycji dla danych binarnych
 - Globalny stopień niezbalansowania $IR = N_{maj}/N_{min}$



Mniej badań dla niezbalansowanych zmiennych strumieni → więcej propozycji w ostatnich latach

- Większość prac dotyczy statycznego lub zmiennego globalnego stopnia niezbalansowania $\{+;- \}$
- Dla momentu t zachodzi $p_t(-) \ll p_t(+)$ albo $p_t(+)\ll p_t(-)$
- Zmiana roli klas (ang. class swap) (Yao, Minku)
- Powiązane IR z innymi zmianami pojęć (concept drift)

Więcej → D. Brzezinski, J. Stefanowski: Ensemble Classifiers for Imbalanced and Evolving Data Streams. In Data Mining in Time Series and Streaming Databases (2018)



Klasyfikatory dla niezbalansowanych strumieni

Różne dla przetwarzania - chunk vs. online

Wprowadzanie elementów modyfikacji danych (resampling)

ROS/RUS, SMOTE i inne techniki + grupowanie → blokowe (np. REA, SERA);
lub online zespoły ; ew. Sliding windows (Krawczyk et al.)

Algorytmiczne

- Modyfikacje pojedynczych modeli (np. VFDT)
- Inne funkcje straty → online ANN, ELM
- Modyfikacje kNN z różną pamięcią (Hammer et al., Ntoutsi et al..)
- Cost sensitive trees
- One-class learning, SVM (Woźniak et al.)
- Wiele zespołów – modyfikacje bagging (OOB, UOB), Adaptive Random Forests; Learn++.CDS; The selective recursive approach (SERA) [Chen, He 2009-2014]; ESOS_ELM [Mirza et al 2015], ...





Prequential AUC

AUC (ROC) → popularna miara oceny / trudna do oblicz. w strumieniu


Nowa propozycja → Prequential AUC

- Obliczenia po każdym przykładzie z wykorzystaniem przesuwne okna
- Oceny przykładów – struktura drzewa czerwono-czarne
- Akceptowalne koszty czas i pamięć – porównywalne do prostszych miar
- Dogodna do niezbalansowanych i zmiennych strumieni
 - Dobrze wskazuje zmiany IR

Original	Predicted	
	+	-
+	TP	FN
-	FP	TN

Inne właściwości

- Statystycznie zgodna z stand. AUC dla stacjonarnych strumieni
- Może być użyte z drift detectors (PH)



w:

s: 0.45	s: 0.60	s: 0.95	s: 0.45	s: 0.70	s: 0.20
l: -	l: -	l: +	l: +	l: +	l: -
t: 1	t: 2	t: 3	t: 4	t: 5	t: 6

Więcej → D. Brzezinski, J. Stefanowski, Prequential AUC for Classifier Evaluation and Drift Detection in Evolving Data Streams. New Frontiers in Mining Complex Patterns ECMLPKDD, 2015.

Prequential AUC: properties of the area under the ROC curve for data streams with concept drift KAIS Journal, vol 52 (2) 2017.

Wizualna analiza miar oceny klasyfikatorów dla niezbalansowanych

Original	Predicted	
	+	-
+	TP	FN
-	FP	TN





Table 2: Properties of selected classification measures; *: contains NaN (undefined value); †: NaN side, *: strong monotonicity

Measure	$TPTN_{max}$	FN_{min}	FP_{min}	$TP_{\nearrow}$	$TN_{\nearrow}$	$TN_{\neq max}$	$\overline{TP}_{\neq max}$	ACE	ACH	UnDefs
Accuracy	✓	x	x	✓ ^s	✓ ^s	✓	✓	x	✓	none
Area Under Lift	x	x	x	✓ ^s	✓ ^s	✓	✓	✓	x	TN-FP; TP-FN
Balanced accuracy	✓	x	x	✓ ^s	✓ ^s	✓	✓	✓	✓	TN-FP; TP-FN
F_1 -score	✓	x [†]	x	✓ ^{s*}	✓ ^{s*}	✓ [*]	✓	x	x	ΔFP-FN-TN
False negative rate	x	x	x	x	✓	x	✓	x	x	TN-FP
False positive rate	x	x	x	✓	x	✓	x	✓	x	TP-FN
$F_\beta, \beta \in [0, \infty)$	✓	x [†]	x	✓ ^{s*}	✓ ^{s*}	✓ [*]	✓	x	x	ΔFP-FN-TN
G-mean	✓	✓	✓	✓	✓	✓	✓	✓	✓	TN-FP; TP-FN
$IBA_\alpha(F_1\text{-score}), \alpha \in (0, \infty)$	x	x [†]	x	x	x	✓ [*]	x	x	x	ΔFP-FN-TN; TP-FN
$IBA_\alpha(G\text{-mean}), \alpha \in (0, \infty)$	x	✓	✓	✓	x	✓	x	✓	x	TN-FP; TP-FN
$IBA_\alpha(F_\beta), \alpha, \beta \in (0, \infty)$	x	x [†]	x	x	x	✓ [*]	x	x	x	ΔFP-FN-TN; TP-FN
Jaccard coefficient	✓	✓	x	✓ ^s	✓	✓	✓	x	x	TN
Kappa	✓	x	x	✓ ^s	✓ ^s	✓	✓	x	x	TN; TP
Log odds-ratio	✓	✓ [*]	✓ [*]	✓ [*]	✓ [*]	x	x	x [†]	✓	TN-FN; TN-FP; TP-FN; TP-FP
MCC	✓	x	x	✓ ^{s*}	✓ ^{s*}	✓ [*]	✓ [*]	x	✓	TN-FN; TN-FP; TP-FN; TP-FP
Neg. predictive value	✓	x	✓ [*]	✓ [*]	✓ [*]	✓	x	✓	x	TP-FP
Optimized precision	✓	x	x	x	x	✓	✓	x	✓	TN-FP; FP-FN; TP-FN
Pointwise AUC-ROC	✓	✓	✓	✓	✓	✓	✓	✓	✓	TN-FP; TP-FN
Precision	✓	✓ [*]	x	✓ [*]	✓ [*]	x	✓	x	✓	TN-FN
Recall	✓	✓	x	✓ ^s	✓ ^s	✓	x	✓	x	TN-FP
Specificity	✓	x	✓	✓ ^s	✓ ^s	x	✓	x	x	TP-FN



- Barycentryczna wizualizacja oraz pożądane własności wartości 22 popularnych miar
 - Analiza zakresu przyjmowanych wartości w zależności od IR
 - Osiąganie wysokich wartości
 - Monotoniczność zmian


Analiza dynamiki zmian miar dla strumieni

+ histogramy gęstości wartości:

Zakres przyjmowanych wartości
zależny od niezbalansowania
strumienia IR

Nie istnieje jedna miara o
najlepszych własnościach, lecz

- G-mean, Balanced Accuracy najbardziej uniwersalne dla odzwierciedlania zmian i IR, także w strumieniach
- Precision i F1 score - trudności dla wyższego niezbalansowania oraz porównywania pomiędzy różnymi danymi
- Kappa i MCC - pomiędzy pow. miarami




Analiza dynamiki zmian miar dla strumieni

Eksperymentalna analiza reakcji na dryft IR z wykorzystaniem różnych miar = różnice w „reagowalności” + odniesienie do gradientów zmian w barycentrycznej wizualizacji

Wyraźne różnice w dynamice zmian wybranych miar

Przydatne dla planowania detektorów zmian i specjalizowanych modeli klasyfikatorów




Rozszerzenia taksonomii rodzajów zmian w niezbalansowanych strumieniach [2019/2021]

Inspiracje badaniami na źródłami trudności danych statycznych → dodatkowe wpływowe czynniki:

- Podział klasy na pod-grupy
- Obecność izolowanych rzadkich grup przykładów mniejszościowych wewnątrz klas większościowych
- Różne rodzaje nakładania się klas (ang. borderline)

Możliwość modelowania poprzez identyfikacje typów przykładów (analiza sąsiedztwa): safe, borderline, rare cases, outliers




Criteria


Drifts

General

Drift region (locality)



local region drift
global drift
global-local region drift



Class composition


Homogeneous



Heterogeneous




class split drift
class merge drift
class split merge drift




Imbalance ratio


Balanced




Imbalanced



dynamic imbalance ratio



class swap




Distribution of minority examples

Safe



Borderline




Rare



Outlier




minority example
distribution change



Class imbalance specific



Więcej w: The impact of data difficulty factors on classification of imbalanced and concept drifting data streams. KAIS 2021




Generator sztucznych danych modelujący wybrane czynniki oraz zmiany

Więcej w: The impact of data difficulty factors on classification of imbalanced and concept drifting data streams. KAIS 2021


Różne reakcje klasyfikatorów na zmiany



Imbalance ratio drift



static imbalance ratio



Split 1->5

Rare 60 drift

Obserwacje ze studium eksperymentalnego

- Globalne niezbalansowanie IR (poza ekstremalnym) nie jest trudne dla badanych klasyfikatorów (specjalizowanych)
- Wyizolowane czynniki – najtrudniejsze: stała obecność i dryf rzadkich przykładów mniejszościowych; fragmentacja klasy (split 3 lub 5); Dla danych wieloklasowych także nakładanie się klas (multi-majority)
 - Wysoki imbalance ratio ($>1:25$) – pogarsza reakcje na powyższe czynniki
- Złożone scenariusze – zbyt trudne dla wszystkich klasyfikatorów UOB lepszym klasyfikatorem niż inne
- Rzeczywiste dane – wszystkie b. złożone czynniki i wielokrotne zmiany (także l. pod-pojęć, rozkładów typów przykładów) → trudność dla wszystkich klasyfikatorów (najlepsze UOB i ESOS-ELM)

Inspiracje dla projektowania nowych detektorów oraz klasyfikatorów

Uwagi końcowe

- Dużo propozycji - często mocno heurystyczne
- Lepsze zrozumienie natury zmian, także jakie rodzaje dryfu są lepiej wykrywane lub obsługiwane w metodach adaptacyjnych
 - W tym b. złożone zmiany - lokalne, powiązane z niezbalansowaniem
- Więcej badań nad strumieniami częściowo nadzorowanymi
- Wykrywania nowych klas oraz częściowych zmian w dekompozycji klas (b. strukturalne lokalne zmiany)
- Uwzględnienia dodatkowej wiedzy w adaptacji
 - Kontekst i czasowe zależności
- Nowe rozwiązania dla uwzględniania złożonych zmian w niezbalansowanych strumieniach
- Aspekty wyjaśnialności (XAI) dla klasyfikacji w strumieniach danych
- ...

Dziękuję za uwagę

Pytania lub komentarze?

Kontakt email:
Jerzy.Stefanowski@cs.put.poznan.pl

lub **www.cs.put.poznan.pl/jstefanowski**