



Predictia geoefectivității ejecțiilor coronale de masă folosind algoritmi de învățare automată

Pricopi Andreea-Clara

Universitatea Tehnică din Cluj-Napoca

Dr. Diana Beșliu-Ionescu,

Dr. Alin Paraschiv (NSO)

Dr. Anca Mărginean (UTCN)



Context

01

Setul de date

02

Algortimi

03

Optimizări

04

Rezultate & discuții

05


Ce e o ejectie de masă coronală?

CME = Coronal Mass Ejection,

o explozie solară


care, în anumite circumstanțe, poate afecta

Pământul




Cum afectează Pământul?

Generând
furtuni geomagnetice
i.e., fiind **geoefective**



Cum știm dacă a avut loc o furtună geomagnetică?

Dst = Disturbance Storm Time,
(index geomagnetic)
 ≤ -30 nT



Ce își propune acest studiu?

Crearea, antrenarea și compararea a 5 modele de **clasificare binară** pentru a determina dacă un CME va fi asociat cu o valoare **$Dst \leq -30$ nT**, utilizând **doar parametri solari** pentru a asigura **timpii maximi de avertizare**

01

Crearea setului de date


Date solare din catalogul SOHO LASCO
Corelarea cu valorile Dst din catalogul Richardson & Cane
Indexul cfi (Comprehensive Flare Index) NOAA

Convenție:
datele sunt tabelare
rânduri = „exemple”
coloane = „atribute”

atribut


exemplu

CPA	AW	Vlin	Acc	CFI	Geoefectiv
360	360	1074	-26.9	54.3	0



02

Analiza setului de date și a problemelor



03

Înțelegerea problemelor

01

Dezechilibru extrem între clase

Peste 99% din evenimente nu au fost geoefective

03

Ambiguitate?

ECM nu sunt singurele evenimente cu potențial geoefectiv
Uneori nu este sigur care ECM a fost cauza


02

Puțini parametri disponibili

Doar 5 variabile independente


04

Algoritmi




01

Regresie logistică




02

KNN




03

SVM



04

ANN



05

Autoencoders

Regresie logistică

Pentru variabilele de intrare X , vrem să obținem predicția $\hat{y}$

$$\hat{y} = P(y = 1 | X)$$

$\hat{y}$ este calculată după formulele din partea dreaptă
și ne dorim să fie **cât mai aproape de valoarea reală y**

$$\hat{y} = \sigma(W^T X + b)$$

$$\sigma(z) = \frac{1}{1 + e^{-z}}$$

Regresie logistică

Cum definim "cât mai aproape de valoarea reală y " ?

Am avea nevoie de un mod de a calcula eroarea față de y ,
dorind să minimizăm această eroare


Regresie logistică

Modul de a calcula eroarea se numește **funcție de cost J**


Algoritmul **modifică valorile W și b** după fiecare calcul al erorii pentru a obține un **cost minim**

$$\mathcal{L}(\hat{y}, y) = -[y * \log(\hat{y}) + (1 - y) * \log(1 - \hat{y})]$$

$$J(W, b) = \frac{1}{m} * \sum_{i=1}^m \mathcal{L}(\hat{y}^{(i)}, y^{(i)})$$



KNN (K-Nearest Neighbors)




"Cine se aseamăună se adună"

Distanța = măsură a similitudinii

Modul de calcul al distanței & K - specificate de noi

Eticheta = votul majoritar al celor K vecini



KNN (K-Nearest Neighbors)

$k = 1$

--> egalitate, poate 1 singur vecin nu e relevant

$k = 2$

--> egalitate, nu avem majoritate

--> k ar trebui să fie impar


$k = 3$

--> albastru

$k = 5$


--> roșu

- putem experimenta cu **diferiți k**
- putem utiliza **ponderi** pentru distanțe (**vecinii mai apropiați să conteze mai mult la vot**)



SVM (Support Vector Machines)


În câte moduri putem trage o linie care să despartă
două clase liniar separabile?
Există un mod optim?



SVM (Support Vector Machines)


maximizarea zonei de mărginire
pentru că distanța până la dreapta de
delimitare indică gradul de încredere

$$\hat{y} = \begin{cases} 0, & W^T X + b < 0 \\ 1, & W^T X + b \geq 0 \end{cases}$$




SVM (Support Vector Machines)

utilizat, de fapt, pentru
găsirea hiperplanului optim
pentru delimitarea a două clase



SVM (Support Vector Machines)

Dar **nu întotdeauna** datele sunt **liniar separabile**
Se consideră, însă, că **există un spațiu n-dimensional** în care ar fi



SVM (Support Vector Machines)

Explicație oferită de Lili Jiang, Quora Data Science Manager

Originally Answered: What are Kernels in Machine Learning and SVM?

Briefly speaking, a kernel is a **shortcut** that helps us do certain calculation faster which otherwise would involve computations in higher dimensional space.

Mathematical definition: $K(x, y) = \langle f(x), f(y) \rangle$. Here K is the kernel function, x, y are n dimensional inputs. f is a map from n -dimension to m -dimension space. $\langle x, y \rangle$ denotes the dot product. usually m is much larger than n .

Intuition: normally **calculating $\langle f(x), f(y) \rangle$** requires us to **calculate $f(x), f(y)$ first**, and **then do the dot product**. These two computation steps can be quite **expensive** as they involve manipulations in m dimensional space, where m can be a large number. But after all the trouble of going to the high dimensional space, the result of the dot product is really a scalar: we come back to one-dimensional space again! Now, the question we have is: do we really need to go through all the trouble to get this one number? do we really have to go to the m -dimensional space? The answer is no, if you find a clever kernel.

SVM (Support Vector Machines)

Explicație oferită de Lili Jiang, Quora Data Science Manager

Simple Example: $x = (x_1, x_2, x_3)$; $y = (y_1, y_2, y_3)$. Then for the function $f(x) = (x_1x_1, x_1x_2, x_1x_3, x_2x_1, x_2x_2, x_2x_3, x_3x_1, x_3x_2, x_3x_3)$, the kernel is $K(x, y) = (\langle x, y \rangle)^2$.

Let's plug in some numbers to make this more intuitive: suppose $x = (1, 2, 3)$; $y = (4, 5, 6)$. Then:

$$f(x) = (1, 2, 3, 2, 4, 6, 3, 6, 9)$$

$$f(y) = (16, 20, 24, 20, 25, 30, 24, 30, 36)$$

$$\langle f(x), f(y) \rangle = 16 + 40 + 72 + 40 + 100 + 180 + 72 + 180 + 324 = 1024$$

A lot of algebra. Mainly because f is a mapping from 3-dimensional to 9 dimensional space.


Now let us use the kernel instead:

$$K(x, y) = (4 + 10 + 18)^2 = 32^2 = 1024$$


Same result, but this calculation is so much easier.

Rețele neuronale artificiale *feedforward*


- **1 nivel de intrare** (inputuri)
- **n nivele ascunse** cu număr variabil de neuroni
- **1 nivel de ieșire** (1 neuron în cazul nostru, pentru că prezicem 1 singur rezultat)



Ce avem într-un neuron?



4| Algoritmi



Rețele neuronale artificiale *feedforward*

- **Funcții de activare uzuale: ReLU, sigmoid**


$$\text{ReLU}(z) = \max(0, z)$$

$$\sigma(z) = \frac{1}{1 + e^{-z}}$$

- **Găsirea arhitecturii unei rețele = găsirea hiperparametrilor optimi**
(hiperparametri = parametri ce nu sunt învățați; e.g. numărul de nivele ascunse, numărul de neuroni, numărul de exemple după care au loc modificările - *batch size* - , rata de învățare)


Autocodificatoarele (*Autoencoders*)

rețele neuronale
speciale, simetrice,
#intrări = #ieșiri,
care învață să
reproducă într-un
mod **simplificat**
datele de intrare



Autocodificatoarele (*Autoencoders*)

pentru
detectia
anomaliilor
pe baza erorii
de
reconstrucție



Optimizări

**PONDERI PENTRU
ECHILIBRAREA
CLASELOR**

Oferă **mai multă importanță** exemplelor din clasa minoritară -
adică "**penalizează**" greșelile mai
tare la antrenare --> face ca
schimbările aduse coeficienților să
fie **mai semnificative**

Necesar pentru a identifica o proporție semnificativă de
evenimente minoritare

Optimizări

**PONDEREA UNUI
EVENTIMENT POTENȚIAL
GEOEFECTIV = $1/2$ *
PONDEREA UNUI
EVENTIMENT GEOEFECTIV**

Am considerat CME-urile
observate cu până la 5 zile
înainte de
furtunile fără o cauză
determinate ca fiind
potențial geoeffective

**Schimbarea semnificativă a fost o creștere de 2% în precizia
rețelei neuronale, dar cu prețul unei scăderi de ~6% pentru
hit rate (sensibilitate)**

Optimizări

UTILIZAREA
ALTUI PRAG
ÎN LOCUL
CLASICULUI
0.5

Comparație pentru
rețeaua neuronală

0.5

Hit rate: 90.8%

Precizie: 8.3%

0.9

72.9%

15.7%

Optimizări

SMOTE SYNTHETIC MINORITY OVERSAMPLING TECHNIQUE

Se alege aleatoriu **1 punct** din clasa
minoritară

Se aleg **K** cei mai apropiați vecini

Se alege **unul dintre vecini** aleatoriu

Se creează un **punct nou aleatoriu pe**
dreapta între cele 2

Rezultatele la antrenare s-au îmbunătățit considerabil, dar la testare pe setul de date originale, rezultatele sunt asemănătoare

Modelul cu cele mai bune rezultate de până acum


ANN cu 1 nivel ascuns,
1 neuron

learning rate = $1e-3$


batch size = 32

epochs = 40

funcții de activare: ReLU &
sigmoid (0.9 threshold)



**Sensibilitate
(hit rate)**



Specificitate

96.7%

Acuratețea

73.9%

Rata de real pozitive

96.4%



Rata de real negative

14.7%

Precizia

**Modelul cu cea
mai bună
precizie
de până acum**

KNN cu:
5 vecini
ponderi uniforme
distanța Minkowski



99.2%

Acuratețea

2.8%

Rata de real pozitive

99.3%

Rata de real negative

56.6%

Precizie

Comparație din punct de vedere al proporției furtunilor identificate & a preciziei

pentru cele mai bune variante pentru fiecare model, cu diverse optimizări

98.4%

Regresia Logistică

7.5%

KNN

78.7%

SVM

73.9%

ANN

85.8%

Autoencoder

3.2%

Regresia Logistică

33.3%

KNN

10.5%

SVM


14.7%

ANN

9%

Autoencoder

UMAP - tehnică
eficientă de reducere a
numărului de
dimensiuni



Vizualizările predicțiilor

Legenda culorilor


TN (albastru) = Real Negative

FP (galben) = Fals Pozitive


TP (verde) = Real Pozitive

FN (roșu) = Fals Negative

Real Negative



Fals & Real Pozitive, Fals Negative




Privind rezultatele dintr-o perspectivă solară

Sensibilitatea este cea mai importantă măsură a performanței, datorită costului asociat unui fals negativ (e de preferat o alarmă falsă în detrimentul unei potențiale furtuni neidentificate)

Majoritatea alarmelor false provin de la un tip de CMEs, denumit halo, care este considerat, în general, cu cel mai mare potențial geoefectiv.


Dintr-o perspectivă fizică, acest lucru era de așteptat.



Îmbunătățiri ulterioare

Încercarea îmbunătățirii rezultatelor cu un model de tip
ansamblu

Studierea rezultatelor după adăugarea unei/unor **informatii**
privind poziția originii ejecției



A wide-angle photograph of Earth from space. The Earth's horizon is a bright blue arc across the middle of the frame. Above the horizon, a bright sun is rising, creating a large, glowing orange and yellow lens flare that fills the upper half of the image. The sky is a deep, dark blue, dotted with numerous small, white stars. The Earth's surface below the horizon is dark and textured, showing the outlines of continents and oceans.

Mulțumesc pentru atenție!

Vreau mai multe informații

De unde pot începe?

1. Scikit-learn

(bibliotecă ce conține majoritatea implementărilor necesare de bază pentru machine learning + exemple)

2. TensorFlow + Keras

(frameworkuri pentru rețele neuronale și deep learning + multe resurse explicative)

3. Hands-On Machine Learning with Scikit-Learn and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems, A. Géron

(carte cu foarte multe exemple practice și explicații simple)

Vreau mai multe informații

De unde pot începe?

4. UMAP

(Documentația oficială: <https://umap-learn.readthedocs.io/en/latest/>)

5. Email-ul meu: andreeapricopi@gmail.com

(Orice întrebări legate de acest proiect sau despre *machine learning* în general)