

METODE INTELIGENTE DE REZOLVARE A PROBLEMELOR REALE



Laura Dioşan
Tema 1

Conținut

- ❑ Instruire automata (Machine Learning - ML)
 - Problematică
 - Proiectarea unui sistem de învățare automată
 - Tipologie
 - ❑ Învățare supervizată
 - ❑ Învățare nesupervizată
 - ❑ Învățare cu întărire
 - ❑ Teoria învățării
- ❑ De citit:
 - S.J. Russell, P. Norvig – Artificial Intelligence - A Modern Approach → capitolul 18, 19, 20
 - Documentele din directoarele: ML, classification, clustering

Învățare automată

□ Problematika

- “How can we build computer systems that automatically improve with experience, and what are the fundamental laws that govern all learning processes?”

□ Aplicații

- Recunoaștere de imagini și semnal vocal
- Computer vision
- Supraveghere bio
- Controlul roboților

Învățare automată

- Arthur Samuel (1959)
 - “field of study that gives computers the ability to learn without being explicitly programmed”
- Tom Mitchell (1998)
 - “a well-posed learning problem is defined as follows: He says that a computer program is set to learn from an experience E with respect to some task T and some performance measure P if its performance on T as measured by P improves with experience E ”
- Herbert Simon:
 - “Learning is any process by which a system improves performance from experience.”
- → Înregistrarea computerelor cu abilitatea de a învăța pe baza experienței

- De ce?
 - **Sisteme computaționale mai bune**
 - Sisteme dificil sau prea costisitor de construit manual
 - Sisteme care se adaptează automat
 - Filtre de spam
 - Descoperirea de informații în baze de date mari → data mining
 - Analize financiare
 - Analize de text/imagini
 - **Înțelegerea organismelor biologice**

Învățarea

- Îmbunătățirea task-ului T
- respectând o metrică de performanță P și
- bazându-se pe experiența E

- Ex. :
 - T: jucarea jocului de dame
 - P: procentul de jocuri câștigate împotriva unui oponent oarecare
 - E: exersarea jocului împotriva lui însuși

 - T: recunoașterea scrisului de mână
 - P: procentul de cuvinte recunoscute corect
 - E: baze de date cu imagini cu cuvinte corect adnotate

 - T: separarea spam-urilor de mesajele obișnuite
 - P: procentul de email-uri corect clasificate (spam sau normal)
 - E: baze de date cu email-uri adnotate

Proiectarea unui sistem de învățare automată

- Îmbunătățirea task-ului T
 - stabilirea scopului (ceea ce trebuie învățat) - funcției obiectiv – și reprezentarea sa
 - alegerea unui algoritm de învățare care să realizeze inferența (previziunea) scopului pe baza experienței
- respectând o metrică de performanță P
 - evaluarea performanțelor algoritmului ales
- bazându-se pe experiența E
 - alegerea bazei de experiență

Proiectare – Alegerea funcției obiectiv

- Care este funcția care trebuie învățată?
 - Ex. pt jocul de dame
 - o funcție care
 - alege următoarea mutare
 - evaluează o mutare
 - obiectivul fiind alegerea celei mai bune mutări

Proiectare – Reprezentarea funcției obiectiv

- Diferite reprezentări
 - tablou (tabel)
 - reguli simbolice
 - funcție numerică
 - funcții probabilistice
 - ex. jocul de dame
 - Combinație liniară a nr. de piese albe, nr. de piese negre, nr. de piese albe compromise la următoarea mutare, nr. de piese negre compromise la următoarea mutare

- Există un compromis între
 - expresivitatea reprezentării și
 - ușurința învățării

- Calculul funcției obiectiv
 - timp polinomial
 - timp non-polinomial

Proiectare – Alegerea unui algoritm de învățare

□ Algoritmul

- folosind datele de antrenament
- induce definirea unor ipoteze care
 - să se potrivească cu datele de antrenament și
 - să generalizeze cât mai bine datele ne-văzute (datele de test)

□ Principiul de lucru

- minimizarea unei erori (funcție de cost – *loss function*)

Proiectare – Învățare automată – tipologie

- Învățare supervizată
- Învățare nesupervizată
- Învățare cu întărire



Învățare supervizată

- Scop:
 - Furnizarea unei ieșiri corecte pentru o nouă intrare

- Tip de probleme
 - regresie
 - Scop: predicția output-ului pentru un input nou
 - Output continuu (nr real)
 - Ex.: predicția prețurilor

 - clasificare
 - Scop: clasificarea (etichetarea) unui nou input
 - Output discret (etichetă dintr-o mulțime predefinită)
 - Ex.: detectarea tumorilor maligne

- Caracteristic
 - BD experimentală adnotată (pt. învățare)




Învățare nesupervizată

- Scop
 - Găsirea unui model sau a unei structuri utile a datelor

- Tip de probleme
 - Identificarea unor grupuri (clusteri)
 - Analiza genelor
 - Procesarea imaginilor
 - Analiza rețelelor sociale
 - Segmentarea pieței
 - Analiza datelor astronomice
 - Clusteri de calculatoare
 - Reducerea dimensiunii
 - Identificarea unor cauze (explicații) ale datelor
 - Modelarea densității datelor

- Caracteristic
 - Datele nu sunt adnotate (etichetate)



Învățare cu întărire

- Scop
 - Învățarea, de-a lungul unei perioade, a unui mod de acțiune (comportament) care să maximizeze recompensele (câștigurile) pe termen lung
- Tip de probleme
 - Ex. Dresarea unui câine (good and bad dog)
- Caracteristic
 - Interacțiunea cu mediul (acțiuni → recompense)
 - Secvență de decizii
- Învățare supervizată
 - Decizie → consecință (cancer malign sau benign)

Teoria învățării

- De unde știm dacă un algoritm de învățare funcționează?
- Cum se aproximează funcțiile?
- Câte date de antrenament sunt necesare?

Proiectare – Evaluarea unui sistem de învățare

□ Experimental

- Compararea diferitelor metode pe diferite date (cross-validare)
- Colectarea datelor pe baza performanței
 - Acuratețe, timp antrenare, timp testare
- Aprecierea diferențelor dpdv statistic

□ Teoretic

- Analiza matematică a algoritmilor și demonstrarea de teoreme
 - Complexitatea computațională
 - Abilitatea de a se potrivi cu datele de antrenament
 - Complexitatea eșantionului relevant pentru o învățare corectă

Proiectare – Evaluarea unui sistem de învățare

Compararea performanțelor a 2 algoritmi în rezolvarea unei probleme

- Indicatori de performanță
 - Parametrii ai unei serii statistice
 - Ex. media
 - Legea normală
 - Proportie calculată pentru serie statistică
 - Indicator variabil, variabilă dummy
 - Ex. Acuratețea
 - Legea binomială

- Comparare pe baza intervalelor de încredere

Proiectare – Evaluarea unui sistem de învățare

Compararea performanțelor a 2 algoritmi în rezolvarea unei probleme → Interval de încredere pentru medie

- Pt o serie statistică:
 - de volum n
 - cu media (calculată) m
 - dispersia σ
- să se determine intervalul de încredere al valorii medii μ
- $P(-z \leq (m - \mu) / (\sigma / \sqrt{n}) \leq z) = 1 - \alpha$
 - → $\mu \in [m - z\sigma / \sqrt{n}, m + z\sigma / \sqrt{n}]$
- $P = 95\% \rightarrow z = 1.96$
- Ex. Problema comisului voiajor rezolvată cu ajutorul algoritmilor evolutivi

$P = 1 - \alpha$	z
99.9%	3.3
99.0%	2.577
98.5%	2.43
97.5%	2.243
95.0%	1.96
90.0%	1.645
85.0%	1.439
75.0%	1.151

Proiectare – Evaluarea unui sistem de învățare

Compararea performanțelor a 2 algoritmi în rezolvarea unei probleme → Interval de încredere pentru acuratețe

- Pt o performanță p (eg. acuratețe)
 - calculată pentru n date
- să se determine intervalul de încredere

- $[p - z(p(1-p)/n)^{1/2}, p + z(p(1-p)/n)^{1/2}]$

- $P = 95\% \rightarrow z = 1.96$

- Ex. Problemă recunoașterii pietonilor rezolvată cu ajutorul Mașinilor cu suport vectorial

$P=1-\alpha$	z
99.9%	3.3
99.0%	2.577
98.5%	2.43
97.5%	2.243
95.0%	1.96
90.0%	1.645
85.0%	1.439
75.0%	1.151

Proiectare – Evaluarea unui sistem de învățare

Compararea performanțelor a 2 algoritmi în rezolvarea unei probleme
→ pe baza intervalelor de încredere

- Pp o problemă și 2 algoritmi a_1 și a_2 care o rezolvă
- Performanțele algoritmilor: p_1 și p_2
- Intervalele de încredere corespunzătoare celor 2 performanțe
 - $I_1 = [p_1 - \Delta_1, p_1 + \Delta_1]$ și
 - $I_2 = [p_2 - \Delta_2, p_2 + \Delta_2]$
- Dacă p_1 e mai bună ca p_2 și
 - dacă $I_1 \cap I_2 = \emptyset \rightarrow a_1$ este mai bun decât a_2 (pt problema dată)
 - dacă $I_1 \cap I_2 \neq \emptyset \rightarrow$ nu se poate spune care algoritm este mai bun

Proiectare – Alegerea bazei de experiență

□ Experiență directă

- Perechi (intrare, ieșire) utile pt. funcția obiectiv
- Ex. Jocul de dame
 - tablă de joc etichetată cu mutare corectă sau incorectă

□ Experiență indirectă

- Feedback util (diferit de perechile I/O) pt funcția obiectiv
- Ex. Jocul de dame
 - secvențe de mutări și scorul final asociat jocului

Proiectare – Alegerea bazei de experiență

□ Surse de date

- Exemple generate aleator
 - Exemple pozitive și negative
- Exemple pozitive colectate de un “învățător” benevol
- Exemple reale

Proiectare – Alegerea bazei de experiență

□ Compoziție

- Date de antrenament
- Date de test

□ Caracteristici

- Datele de antrenament și de test trebuie
 - să fie independente
 - Dacă nu → clasificare colectivă
 - să urmeze aceeași lege de distribuție
 - Dacă nu → învățare prin transfer (transfer learning/inductive transfer)
 - recunoașterea mașinilor → recunoașterea camioanelor
 - analiza textelor
 - filtre de spam

Proiectare – Alegerea bazei de experiență

- Tipuri de attribute ale datelor
 - Cantitative → scară nominală sau rațională
 - Valori continue → greutatea
 - Valori discrete → numărul de computere
 - Valori de tip interval → durata unor evenimente

 - Calitative
 - Nominale → culoarea
 - Ordinale → intensitatea sunetului (joasă, medie, înaltă)

 - Structurate
 - Arbori – rădăcina este o generalizare a copiilor (vehicol → mașină, autobus, tractor, camion)

Proiectare – Alegerea bazei de experiență

□ Transformări asupra datelor

■ Standardizare → attribute numerice

- Înlăturarea efectelor de scară (scări și unități de măsură diferite)
- Valorile brute se transformă în scoruri z
 - $Z_{ij} = (x_{ij} - \mu_j) / \sigma_j$, unde x_{ij} – valoarea atributului al j -lea al instanței i , μ_j (σ_j) este media (abaterea) atributelor j pt. toate instanțele

■ Selectarea anumitor attribute