

Retinaképek klasszifikálása konvolúciós hálóval

Vas Bernadett

Önálló projekt III.

2022. 12. 22.

Tartalom

- Ordinal classification
- Megoldási módszerek I.: Architektúra és címke-módosítás
- Megoldási módszerek II.: Veszteségfüggvény-módosítás
- Mérési eredmények

Ordinal classification

- Diabetikus retinopátia ötosztályos klasszifikációja
- Az adathalmaz címkéi:
 - 0-s osztály: teljesen egészséges
 - 1-es osztály: enyhe
 - 2-es osztály: közepesen súlyos
 - 3-as osztály: súlyos
 - 4-es osztály: poliferatív
- Az osztályok egy romló folyamatot írnak le: diszkrét címkék, de rendezettek, skálaszerűek
- Nem ugyanolyan mértékűek a téves klasszifikálások
- Az ordinal classification egyéb alkalmazásai:
 - kor megállapítása felvételekből,
 - termékek és szolgáltatások értékelése

Ordinal classification

- Miért nem jó a többosztályú klasszifikáció?
 - Független osztályokat feltételez
 - Elveszik a rendezettségi információ
- Miért nem jó a regresszió?
 - Folytonos numerikus értéként tekintheti a címkéket
 - Azt feltételezheti, hogy a szomszédos osztályok egyforma távol vannak egymástól
 - Példák: betegség stádiumai, korosodás gyerekkorban illetve felnőttkorban

Bináris klasszifikációs részfeladatok

Multiclass classification

- Input: $\mathbf{x}^{[i]}$; a címke one-hot vektorként pl $y_i = [0, 0, 1, 0, 0]$
- A háló kimenete: egy $o = (o_1, \dots, o_K)$ valószínűségeloszlás
- Ha a kategória k , akkor o_k legyen közel 1-hez

Niu & Zhou, 2016, *age estimation*

- Címkék: ordinal one-hot, azaz $y_i = [1, 1, \dots, 1, 0, 0, \dots, 0]$
- Egyetlen konvolúciós háló, az utolsó sűrű rétegben $K - 1$ klasszifikátor, mindegyik két neuront foglal magában
- A t -edik klasszifikátor feladta: $\hat{y}_i^t = P(y_i > r_t)$ megjóslása, ahol r_t a t -edik súlyossági kategória
- Ha a kategória k , akkor $\forall i \leq k$ -ra o_i legyen közel 1-hez
- Cross-entropy-val tanítható: a bináris cross-entropy-kat aggregáljuk
- A predikció számolása: $q_i = \sum_{t=1}^{K-1} \mathbb{1}\{\hat{y}_i^t \geq 0.5\}$

Inkonzisztencia

- Probléma a bináris részfeladatokra bontással: inkonzisztens kimeneti valószínűségeket kaphatunk
- Ekkor kevésbé lesz magyarázható, értelmezhető a kimenet, illetve nem felel meg az elvárásunknak sem, miszerint $y_i > r_t$ akkor $y_i > r_l$ ahol $l < t$
- Konzisztens (rang-monoton) kimenetek:
$$P(y_i > r_1) \geq P(y_i > r_2) \geq \dots \geq P(y_i > r_{K-1})$$

CORAL (Consistent Rank Logits, 2020)

- Ordinal one-hot címkék
- Egyetlen architektúra, az utolsó sűrű rétegben $K - 1$ klasszifikátor, mindegyik egy kimeneti neuronnal rendelkezik
- A $K - 1$ klasszifikátor ugyanazokkal a súlyparaméterekkel dolgozik, de más torzítás értékekkel, azaz

$$\hat{y}_i^k = P(y_i > r_k) = \sigma\left(\sum_{j=1}^m w_j a_j + b_k\right) = \sigma(g(\mathbf{x}^{[i]}, \mathbf{W}) + b_k)$$

- A közös súlyok, különböző torzítások garantálják a rang-monotonitást
- Veszteségfüggvény : A $K - 1$ klasszifikáló súlyozott cross-entropy-ja
- A predikciós számolás az előzőhöz hasonlóan történik

- CORAL javítása
- A súlymegosztás az utolsó, sűrű rétegben korlátozhatja a háló kifejezőképességét
- Cél: konzisztencia elérése, súlymegosztás nélkül
- Megoldás: Conditional Ordinal Regression for Neural Networks (CORN)

Unimodális eloszlások

- Új megközelítési mód: a kimeneti valószínűségek unimodális eloszlásra való kényszerítése
- Történhet architektúra-módosítással, illetve a veszteségfüggvény átalakításával is

Veszteségfüggvény módosítás: CO2 loss (2021)

- Az unimodális eloszlástól való eltérés büntetése regularizációs taggal
- A büntetések nagysága arányos az egymást követő valószínűségek különbségével

$$CO2(\mathbf{y}, \hat{\mathbf{y}}) = L(\mathbf{y}, \hat{\mathbf{y}}) + \lambda \cdot f, \text{ ahol}$$

$$f = \sum_{k=1}^{K-1} \mathbb{1}\{k \geq k_i^*\} ReLU(\delta + \hat{y}_{i,k+1} - \hat{y}_{i,k}) + \sum_{k=1}^{K-1} \mathbb{1}\{k \leq k_i^*\} ReLU(\delta + \hat{y}_{i,k} - \hat{y}_{i,k+1})$$

$$\text{és } \lambda \geq 0, \delta > 0.$$

- A predikció számolható a legnagyobb valószínűség kiválasztásával, vagy expectation trick-el is, tehát amikor a valószínűségekkel súlyozott összegét vesszük a címkéknek: $\sum_{i=0}^{K-1} p_i c_i$

Veszteségfüggvény módosítás: CDW-CE loss (2022)

- Cross-entropy átalakítása, hogy a rossz predikciók büntetésein legyen a hangsúly
- Rossz predikció esetében arra ösztökéli a modellt, csökkentse az ahhoz tartozó valószínűséget
- A büntetés a címkepárok távolságaival arányos

$$\text{CDW-CE} = - \sum_{i=0}^{K-1} \log(1 - \hat{y}_i) \cdot |i - c|^\alpha, \text{ ahol } \alpha \text{ hiperparaméter}$$

Mérések

Adathalmaz

- Tanítóhalmaz: Kaggle EyePACS
- Teszthalmaz: Kaggle EyePACS, IDRID, DDR
- Képek előfeldolgozása: zaj csökkentése, kontraszt javítása, nem informatív területek méretének csökkentése

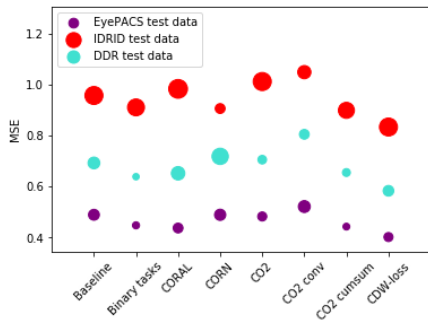
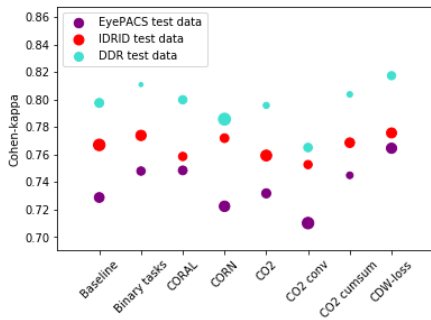
Konvolúciós háló

- EfficientNet-B3

Metrikák

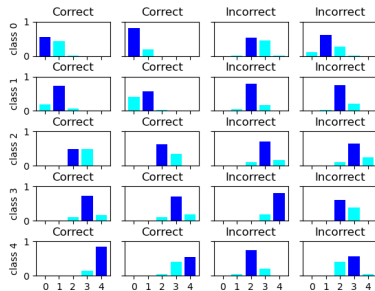
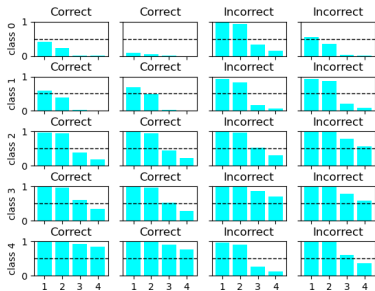
- Kvadratikus Cohen-kappa
- Tévesztés mátrix
- MSE

Mérési eredmények



ábra: Cohen-kappa és MSE értékek a három különböző tesztalmon


Kimeneti valószínűségek



ábra: Véletlenül választott adatpontok kimeneti valószínűségei a CORAL modellből, illetve a CDW loss-al tanított modellből

Motiváció az ensemble modellhez

- A CDW-vel tanított modell jól teljesít a 2-3-4 osztályokon
- A CO2-vel tanított modell, aminek predikcióit expectation trick-el számoltuk, relatíve jól különbözteti meg a 0-1 osztályt



ábra: A CDW-vel tanított, illetve a CO2 és expectation trick kombinációval tanított modellek tévesztés mátrixai

Köszönöm a figyelmet!