

adott rács egy olyan bázisát találják meg, amely vektorai közel vannak a merőlegeshez, azaz amelynek az úgynevezett ortogonalitási defektusa kellően kicsi.

Bemutatjuk egy rács ortogonalitási defektusának három hasznos alakját és megmutatjuk, hogy ez hogyan vezet el Kannan algoritmusához, amely pontos megoldást nyújt az SVP-re. Bevezetjük a Voronoi defektus fogalmát amely az ortogonalitási defektushoz hasonló, csak ez Kannan CVP-re nyújtott algoritmusának felel meg.

Bevezetjük a redukciós tartományok fogalmát és ennek segítségével bemutatjuk az LLL algoritmus egy kevésbé kutatott testvérét, amely minimális ortogonalitási defektusú bázist talál az első 4 dimenzióban. Ennek segítségével jobban megértjük az alacsony dimenziós esetet, és talán az LLL algoritmus működését is. Megvizsgáljuk ezen algoritmus futását magasabb dimenzióban, és az algoritmus iterációinak számára egy új felső korlátot adunk.

Klinikailag releváns szegmentációs metrika nyomában: a Medical Similarity Index (MSI) definíciója és implementációja

FAZEKAS SZUZINA

Semmelweis Egyetem

Bevezetés: A radiológia területén naponta egyre növekvő számú kép keletkezik. Az orvosi területen különböző szövetek és szervek szegmentálása kulcsfontosságú a diagnosztikában és a terápiában. Az arany standard a szakértő által végzett manuális szegmentáció, de napjainkban egyre több gépi tanuláson alapuló automatikus szegmentációs módszer létezik. Ennek következtében felmerült az igény az aktuális szegmentáció pontosságának értékelésére. Különböző széles körben használt terület alapú és távolság alapú metrikák léteznek, amelyeket a szegmentáció pontosságának értékelésére használnak. Ezen metrikák csak geometriai tulajdonságokat foglalnak magukba, és nem adaptálhatók különböző klinikai alkalmazásokhoz.

Célkitűzés: Célunk az volt, hogy definiáljunk és megvalósítsunk egy klinikailag releváns szegmentációs metrikát, amely lehetőséget nyújt különböző klinikai alkalmazásokhoz való adaptációra.

Módszerek: Egy referenciakontúrt használunk, amelyet az arany standard szegmentációnak tekintünk, és meghatározzuk a tesztkontúr egyezőségét a referenciakontúrral. Meghatározzuk a kétirányú helyi távolságot, és ennek a távolságnak megfelelően párosítjuk a tesztkontúr pontjait a referenciakontúr pontjaival. A teszt- és referencia középpont távolságával való korrigálás után kiszámítjuk az euklideszi távolságot a párosított pontok között, és pontszámot adunk minden referencia ponthoz. Az általános orvosi hasonlósági indexet úgy számoljuk, mint az összes tesztpont pontszámának átlagát.

Eredmények: Létrehoztunk egy képfeldolgozási keretrendszer Python programozási nyelven. A kód elérhető egy nyilvános GitHub repository-ban, és biztosítunk egy futtatható Google Colaboratory munkafüzetet is. Az algoritmus több szeletből álló képeket is kezel, egy szeleten több maszk is lehet. Létrehoztunk egy maszk vágási algoritmust, amely képes

elválasztani a konkáv maszkokat. 40 neurális hálózat által javasolt orvosi képmaszk értékelése alapján finomhangoltuk metrikánk tulajdonságait. Következtetés: Megvalósítottunk egy új szegmentációértékelési metrikát Kim és mtsai. ötlete alapján [1], és biztosítottunk egy keretrendszert, amely könnyen használható az orvosi kép szegmentáció klinikai relevanciájának automatikus mérésére.

Támogatások: A publikáció, illetve az annak keretében ismertett tudományos eredmény a Richter Gedeon Nyrt. által létrehozott Richter Gedeon Talentum Alapítvány (székhely: 1103 Budapest, Gyömrői út 19-21.) támogatásával, „Richter Gedeon kiválósági PhD Ösztöndíj” keretében készült.

[1] H. Kim, J. I. Monroe, I., S. Lo, M. Yao, P. M. Harari, M. Machtay, J. W. Sohn, Quantitative evaluation of image segmentation incorporating medical consideration functions, *Med. Phys.* **42**(2015), No. 6, 3013—3023.

Mélytanulás módosított JoCoR modellekkel zajos címkék esetén

FÓRIÁN LÁSZLÓ, FAZEKAS ISTVÁN, BARTA ATTILA

Debreceni Egyetem, Informatikai Kar,
Alkalmazott Matematika és Valószínűségszámítás Tanszék

A mély neurális hálózatok az utóbbi években nagy pontosságot értek el képek osztályozására vonatkozó feladatokban. Ugyanakkor ezen modelleknek nagy mennyiségű tanuló adatra van szükségük helyes osztály-címkékkel ellátva. Ez viszont nem mindig elérhető, a rendelkezésre álló adathalmazokban gyakran fordulnak elő zajos, hibás címkék, ezért vált fontos kutatási területté a gépi tanulás zajos címkék mellett.

Munkánkban [1] egy nemrég megjelent módszer, a JoCoR [2] további javításának lehetőségeit vizsgáltuk ezen probléma kapcsán. Módosításokat végeztünk a tanulási folyamat több pontján, kiértékeljük ezeket a modelleket és levontuk következtetéseinket.

A JoCoR módszer alkalmazza a kicsi veszteségfüggvény-értékekkel rendelkező elemek kiválasztásának ötletét, illetve két neurális hálózat működik benne, amelyek között fokozatosan növeli az összhangot. Ez egy olyan hibafüggvény segítségével valósul meg, amely a két hálózat kimenetei (mint diszkrét valószínűségi eloszlások) közötti eltérést méri. Ennek regularizációs hatása is van, illetve fontos szerepe van a túltanulás, túlillesztés megelőzésében is. A JoCoR módszer konvolúciós hálózatokat (CNN) használ, de a háttérben lévő neurális háló kicserélhető más modellre is. Az összetett modell paramétereit az együttes veszteségfüggvény segítségével kerülnek meghatározásra, amely a két hálózat keresztentropia-veszteségfüggvényeinek, illetve a regularizációs tagnak a súlyozott összege. Az utóbbi mennyiség egy szimmetrikus Kullback–Leibler eltérés (két KL tag összege: $D_{KL}(p||q) + D_{KL}(q||p)$ ahol p és q a softmax output-okból kapott két diszkrét eloszlás). Azokat a címkéket tekintjük helyesnek, amelyekhez tartozó együttes veszteségfüggvény-érték kicsi.