

СЕГМЕНТАЦИЈА СЛИКЕ k -НН МЕТОДОМ **k -NN IMAGE SEGMENTATION**

Букашин Граовац, Небојша Ралевић, Лидија Крстановић, *Факултет техничких наука, Нови Сад*

Област – МАТЕМАТИКА У ТЕХНИЦИ

Кратак садржај – Главна тема рада јесте примена k -НН алгоритма за сегментацију слике. На почетку су дате теоријске основе о дигиталној обради слике уопште, а остатак рада је фокусиран на опис и примену алгоритма у програмском језику MATLAB. На самом крају рада у оквиру апендикса налазе се потребне дефиниције, теореме и докази за дубље разумевање математичке стране текста.

Abstract – The main subject of the paper is application of k -NN algorithm for image segmentation. Theoretical basis of digital image processing is given in the beginning. The rest of the paper focuses on the description and the application of the algorithm in MATLAB. Finally, in the appendix, definitions, theorems and proofs for deeper mathematical understanding are given.

Кључне речи: Сегментација слике, k -НН алгоритам, MATLAB, математика.

1. УВОД

Сегментација слике представља један мали део широке области дигиталне обраде слике. Једноставно речено, слику можемо дефинисати као дводимензионалну функцију $f(x, y)$, где су x и y просторне координате, а вредност функције f за сваку координату (x, y) називамо *интензитетом сиве боје* у тој тачки.

Ако су све вредности слике x , y и $f(x, y)$ коначне, тада ту слику називамо *дигиталном*. Кроз године истраживања и развијања није искристалисан договор где обрада слике престаје, а остале области као што су компјутерска визија и анализа слике почињу. Најчешће, прихвата се договор да је обрада слике дисциплина у којој су и улазне и излазне вредности слике.

2. О ДИГИТАЛНОЈ ОБРАДИ СЛИКЕ


Почетци дигиталне обраде слике јављају се у новинарству. Једна од првих примена била је почетком XX века када су слике послате подморским каблом од Лондона до Њујорка. Ова метода била је веома спора, те је почетком 20-их година уведен Бартлејн кабл за размену слика који је смањио потребно време за слање на мање од три сата.

Слика 1 послата је 1921. године и реконструисана је штампањем посебних карактера који се називају полутонови. Техника штампања била је врло непрецизна у смислу интензитета слике, па је већ крајем исте године овај метод престао да се користи.



Слика 1: Квалитет слике послате 1921. године

Нови поступак настао је већ 1922. године и омогућио је пет нивоа сиве боје. Слика 2 послата је другом методом такође путем Бартлејн кабла. Одступања у квалитету слике су уочљива, али ако упоредимо са Сликаом 1 разлике су очигледне, како у интензитету, тако и у резолуцији.



Слика 2: Квалитет слике послате 1922. године

1929. године квалитет слања слике је знатно порастао са пет на чак 15 нивоа сиве боје, што је веома утицало на квалитет и детаље на слици.

Претходно описани поступци, иако представљају начин слања дигиталне слике, у ствари не спадају директно у дигиталну обраду слике којом се ми данас бавимо, јер за њихово процесирање нису били потребни рачунари. Тако је историја и развој

НАПОМЕНА:

Овај рад проистекао је из мастер рада чији је ментор био др Небојша Ралевић, ред. проф.

дигиталне обраде слике уско повезана са историјом и развојем рачунара. У ствари дигиталне слике захтевају изузетно велику могућност складиштења података као и јаке рачунарске машине да комплетан њен процес искључиво зависи од развоја рачунара и помоћних компоненти као што су хард диск, екран, графичка карта, итд. Модерни дигитални рачунар потиче из 40-их година прошлог века и развојем његових компоненти почетком 60-их година дошло се до довољно моћног рачунара који може да врши дигиталну обраду слике. Велики допринос развоју у ранијем периоду донели су космички програми који су између осталог развијали софтвере за кристалисање слике Месеца. Касније током година велику улогу одиграла је медицина, а најважнијим открићем сматра се компјутеризована томографија (СТ). То је радиолошки метод снимања који поред рендген зрачења користи и томографију, тј. метод који се заснива на математичкој процедури обраде снимка или томографској реконструкцији снимка уз примену дигиталних рачунара и програмских пакета.

Увођењем и развојем дигиталне обраде слике у космичке програме и медицину отворен је пут за примену у разним другим гранама науке. Тако се данас ова област користи и у биологији за изоштравање слике како би се могле уочити погодне информације потребне за неки експеримент. Географи користе сличне методе за уочавање степена загађења планете на сателитским снимцима. Археолози такође користе сличне методе за изоштравање неких историјских слика које су временом постале замућене или су се оштетиле неким спољним фактором. Физичари за резултате својих експеримената користе погодне методе за дигиталну обраду слике, и многи други.

2.1. Примена дигиталне обраде слике

Развој дигиталне обраде слике је толико напредовао да је данас готово немогуће пронаћи област у којој се не користи. Најчешће и најпознатије су слике настале електромагнетским зрачењем. То је комбинација осцилујућег електричног и магнетног поља која заједно путују кроз простор у облику међусобно управних таласа. Интерпретира се као талас који се приказује као самопропагирајући трансверзално осцилирајући талас електричног и магнетног поља. Честице које квантификују електромагнетско зрачење су фотони. Ако бисмо посматрали таласе према енергији коју поседује један фотон, добили бисмо хијерархију слика насталих електромагнетским зрачењем. На првом месту са највећом количином енергије у једном фотону су γ – зраци, затим X – зраци, UV – зраци, светлосни зраци, инфрацрвени зраци, микроталасни зраци и на крају радио таласи који поседују најмању количину енергије у једном фотону.

3. k -НН АЛГОРИТАМ ЗА СЕГМЕНТАЦИЈУ СЛИКЕ

Ова метода се још назива и *Алгоритам k најближих суседа* и представља непараметарски метод који се користи за класификацију и регресију. У оба случаја улаз се састоји од k најближих тест примера у

функцији простора, а излаз зависи од тога да ли се алгоритам користио за класификацију или регресију.

- У класификацији излаз је члан класе. Објекат се класификује гласовима већине својих суседа, тако да буде распоређен у класу најчешћу међу својих k најближих суседа. k је позитиван цео број и најчешће има малу вредност.
- У регресији, излаз представља вредност објекта. Ова вредност представља просек вредности његових k најближих суседа.

Пре него што се одредимо за имплементацију овог алгоритма, потребно је кроз три основна аспекта оценити да ли ће алгоритам дати жељене резултате, а то су:

1. Једноставност тумачења излазних вредности,
2. Потребно време за извршавање алгоритма,
3. Предвиђање ефективности.

Тешко је рећи који од ова три аспекта је најважнији, али ако бисмо гледали са становишта пројекта на коме радимо, онда је предвиђање ефективности сигурно најважнија ставка, јер без обзира на потребно време и сложеност посла, ипак је најбитније да добијемо потребне резултате за даљи рад.

Овај алгоритам је један од најједноставнијих алгоритама машинског учења, јер се његово учење заснива на примерима, тј. апроксимација функције је локалног типа и сва израчунавања зависе од класификације.


3.1. Опис k -НН алгоритма

Тест примери су вектори у вишедимензионалној функцији простора, где сваки има класну ознаку. Тест фаза алгоритма састоји се у складиштењу будућих вектора и класних ознака тест примера. У фази класификације, k је константа дефинисана од стране корисника, а неозначени вектор се класификује доделом ознаке која је најучесталија међу k тест примера најближих датом упиту. Најчешће се користи Еуклидово растојање за непрекидне променљиве. За дискретне променљиве, као што је класификација текста, користи се другачија техника, као што је на пример функција раздаљине засноване на преклапању (Хамингово растојање).

Мана класичне класификације испољава се када је класна дистрибуција искривљена. Тако примери учесталијих класа теже доминацији при предвиђању нових примера, јер теже да, упркос њиховом великом броју, буду чести међу k најближих суседа. Један од начина да се превазиђе овај проблем јесте да се дода тежина класификацији, узимајући у обзир растојање од тест тачке до сваког од k најближих суседа. Класа сваке од k најближих тачака множи се тежином пропорционалном инверзу растојања од дате тачке до тест тачке. Други начин превазилажења овог проблема огледа се у апстракцији репрезентације података. На пример, у самоорганизујућој мапи, сваки чвор је представник (средиште) скупине сличних тачака, без обзира на њихову густину у оригиналним тест подацима.


Читањем претходног описа како функционише наш алгоритам, многи ће и даље остати без одговора на то питање. Сходно томе, навешћемо врло једноставан пример помоћу кога ће читалац створити визуелну репрезентацију шта се дешава у позадини алгоритма.

Пример 1. Нека је дат координатни систем, и у њему три црвена круга, три зелена правоугаоника и једна плава звезда, као на следећој слици:



Слика 3: Приказ података у равни


Обележимо црвене кругове са ЦК, зелене правоугаонике са ЗП и плаву звезду са ПЗ. Желимо да нађемо класу ПЗ. ПЗ може бити ЦК или ЗП и ништа друго. Тражимо k алгоритмом k -НН. Нека је $k = 3$. Даље, повлачимо кружницу са центром у ПЗ таквог полупречника да се у њој налазе тачно три објекта у равни, као на следећој слици:



Слика 4: Бирање k суседа


Три најближа објекта класи ПЗ су сви објекти из класе ЦК. Дакле, са сигурношћу можемо рећи да ПЗ треба да припада класи ЦК.

У овом примеру одабир је био веома очигледан, јер су заиста три најближа објекта звезди црвени кругови. Као што се може претпоставити, одабир параметра k је од високог значаја за ефекат алгоритма, и у наставку дајемо кратак опис како то радимо у пракси. Пре свега, размотримо од каквог је значаја параметар k у алгоритму. У претходном примеру, имали смо свега шест параметара и дату вредност $k = 3$ помоћу које смо лако одредили границе тражене класе. Те границе су одвојиле класу ЦК од класе ЗП. На сличан начин можемо посматрати проблем и када имамо више тачака у равни, и видећемо какав утицај има вредност параметра k на резултат алгоритма. На слици 5 налази се графички приказ црвених и плавих тачака у равни и грађење границе између њих у односу на величину параметра k . Ако погледамо слику пажљиво, примећујемо да порастом параметра k граница постаје равнија. Ако пустимо да $k \rightarrow \infty$ коначно цела слика постаје плава или црвена, у зависности од тога који елементи су у већини.




Слика 5: Грађење границе у односу на промену параметра k

Грешка у току тренирања и грешка у току валидације алгоритма су два параметра која треба испитати и утврдити у односу на промену параметра k . На слици 6 налази се крива која представља грешку у току тренирања у односу на промену параметра k .



Слика 6: Крива грешке у току тренирања

Као што се може приметити вредност грешке за $k = 1$ је увек нула. Разлог томе је што најближа тачка свакој коју смо изабрали у току тренинга је она сама. Стога је претпоставка $k = 1$ увек тачна. Уколико је и валидациона грешка слична, избор за k ће бити 1. На слици 7 налази се крива која представља грешку у току валидације у односу на промену параметра k .



Слика 7: Крива грешке у току валидације

Приказивањем графика на слици 7 ствари постају јасније. Наиме, за $k = 1$ долази до преклапања

граница, па стога грешка истог тренутка нагло опада и достиже минимум. Након достизања минимума, полако опет почиње да расте са порастом параметра k . Да бисмо добили оптималну вредност за k , потребно је развојити тренирање и валидацију од улазног скупа. На крају, цртањем криве грешке у току валидације добијамо оптималну вредност параметра k . Добијана вредност за k се користи за сва даља испитивања.

3.2. Псеудо код k -НН алгоритма

Извршавање једног k -НН алгоритма врши се на следећи начин:

1. Учитати податке.
2. Одредити параметар k .
3. За добијање тражене класе, учитати почевши од једног податка па навише.
 - 3.1 Израчунати раздаљину између тест података и података за тренинг. У овом кораку се користи Еуклидово растојање.
 - 3.2 Сортирати добијене резултате раздаљине у нерастућем редоследу.
 - 3.3 Изабрати првих k из корака 3.2.
 - 3.4 Изабрати најчешће коришћену класу од одабраних k из корака 3.3.
 - 3.5 Приказати тражену класу.

3.3. Проблематика

Најбољи избор за вредност k зависи од податка. Генерално, веће вредности за k смањују ефекат погрешне класификације, али су зато границе међу класама мање јасне. Дobar одабир вредности k може се извести различитим хеуристикама. Посебан случај јесте када је предвиђено да класа буде класа најближих тест примера (нпр. када је $k = 1$), назива се алгоритам најближег суседа. Тачност k -НН алгоритма може бити озбиљно смањена уколико су присутне грешке, нерелевантне одлуке или одлуке нису у складу са њиховом важношћу.

Наивна верзија алгоритма је једноставна за примену. Рачунају се растојања од тест примера до свих сачуваних примера. Међутим, ово је рачунски захтевно уколико радимо над великим скуповима. Коришћењем одговарајућег алгоритма претраге најближег суседа k -НН постаје рачунски обрадив чак и за изузетно велике скупове. До сада су предложени многи алгоритми претраге најближег суседа и генерално сви предлози настоје да смање број изведених израчунавања растојања.

3.4. Учење растојања

Учинак k -НН алгоритма се може значајно побољшати помоћу учења растојања. Условно речено, потребно је „надгледати“ како се понаша алгоритам, и на тај начин донети погодну одлуку. Најчешће коришћени алгоритми су *neighbourhood components analysis* и *large margin nearest neighbor* (видети [3] и [4]). Ови алгоритми користе означене информације да науче функцију метрике или псеудо-метрику.

4. ЗАКЉУЧАК

Да бисмо добили најефикаснији алгоритам, потребно је добро познавати скуп над којим вршимо анализу. У почетку, испитивање и доношење закључака биће врло дуготрајни и мучни, међутим, временом се повећава искуство а самим тим смањује количина потребног времена за доношење релевантних одлука. Као што се може уочити, одабир параметра k је најважнији и за његово одређивање потребно је издвојити највише времена. Како је овај алгоритам веома познат у области сегментације слике, у зависности од специфичности улазних података може се пронаћи у претходним истраживањима која је неко извршио релевантан закључак за одабир траженог параметра.

Иако k -НН алгоритам није сложен као неки алгоритми који се у модерно време користе, и даље има широку примену у разним гранима науке, а посебно у сегментацији слике. Овај кратак рад служи искључиво да заинтересује читаоца, а за дубље разумевање потребно је прочитати мастер рад аутора или погледати неку од књига наведених у литератури.


5. ЛИТЕРАТУРА

- [1] R. Gonzalez, R. Woods, “*Digital Image Processing*”, London, Pearson, 2017.
- [2] N.S. Altman, “*An Introduction to Kernel and Nearest-Neighbor Nonparametric Regression*”, Riverside, The American Statistician, Vol. 46, No. 3, pp. 175-185, 1992.
- [3] K.Q. Weinberger, J. Blitzer, L.K. Saul, “*Distance Metric Learning for Large Margin Nearest Neighbor Classification*”, Philadelphia, 2006.
- [4] J. Goldberger, S. Roweis, G. Hinton, R. Salakhudinov, “*Neighbourhood Components Analysis*”, Toronto, 2005.

Кратка биографија:



Вукашин Граовац рођен је 1993. године у Београду, основну и средњу школу завршио у Старој Пазови. Основне студије математике на Природно-математичком факултету завршава 2017. године и исте године уписује мастер студије математике у техници са усмерењем ка програмирању.



Небојша Ралевић рођен је 1965. године у Иванграду. Докторирао је 1997. године, а од 2010. године ради као редовни професор на Факултету техничких наука у Новом Саду.



Лидија Крстановић рођена је 1985. године у Новом Саду. Докторирала је 2017. године, а од 2018. године ради као доцент на Факултету техничких наука у Новом Саду.