

**ČESKÁ ZEMĚĚLSKÁ UNIVERZITA V PRAZE**

**FAKULTA ŽIVOTNÍHO PROSTŘEDÍ**

**KATEDRA PROSTOROVÝCH VĚD**



**MODELOVÁNÍ LESNÍCH POŽÁRŮ  
V KALIFORNII METODOU GEOGRAFICKÉ  
VÁŽENÉ REGRESE**

**BAKALÁŘSKÁ PRÁCE**

**VEDOUCÍ PRÁCE: D. Sc. (Tech.) Olga Špatenková  
BAKALANT: Dominik Šamanek**

© 2022 ČZU v Praze

# ČESKÁ ZEMĚDĚLSKÁ UNIVERZITA V PRAZE

Fakulta životního prostředí

## ZADÁNÍ BAKALÁŘSKÉ PRÁCE

Dominik Šamanek

Geografické informační systémy a dálkový průzkum Země v životním prostředí

Název práce

Modelování lesních požárů v Kalifornii metodou geograficky vážené regrese

Název anglicky

Modeling of forest fires in California using the geographically weighted regression

---

**Cíle práce**

Práce se věnuje modelování rizika vzniku lesních požárů v Kalifornii. Teoretická část představí postupy, které se uplatňují v současné praxi. V praktické části se pak zaměří na požáry z let 2000-2020 s cílem vytvořit zjednodušený model popisující jejich vznik. Budou stanoveny hlavní faktory spjaté s výskytem požárů a příslušné vztahy budou kvantifikovány. Dále bude zhodnocena kvalita výsledného modelu.

**Metodika**

Aplikována bude metoda geograficky vážené regrese, která je vhodná pro modelování jevů s prostorově proměnlivými vztahy. Výsledný geograficky vážený model bude statisticky vyhodnocen a porovnán s modelem globálním pro posouzení vhodnosti aplikace lokálního modelování. Výsledky budou vhodně znázorněny pomocí mapových výstupů a podrobně interpretovány.

**Doporučený rozsah práce**

30-40 stran

**Klíčová slova**

Vhodná klíčová slova budou zvolena autorem práce.

**Doporučené zdroje informací**

- FOTHERINGHAM, A S. – CHARLTON, M. – BRUNSDON, C. *Geographically weighted regression : the analysis of spatially varying relationships*. Chichester: Wiley, 2002. ISBN 0-471-49616-2.
- Gill A. M., Stephens, S. L. and Cary G. J., 2013: The worldwide "wildfire" problem. *Ecological Applications*, 23: 438-454
- Koutsias, Nikos & Martínez-Fernández, Jesús & Allgöwer, Britta. (2010). Do Factors Causing Wildfires Vary in Space? Evidence from Geographically Weighted Regression. *GIScience & Remote Sensing*. 47. 221-240.
- Martínez-Fernández, Koutsias, Chuvieco, Allgöwer (2005). Modelling Wildland Fire Occurrence in Southern Europe by Geographically Weighted Regression Approach. In: 5th International Workshop on Remote Sensing and GIS Applications to Forest Fire Management: Fire Effects Assessment (pp.57-60)

**Předběžný termín obhajoby**

2021/22 LS – FZP

**Vedoucí práce**

D.Sc. Olga Špatenková

**Garantující pracoviště**

Katedra prostorových věd

Elektronicky schváleno dne 22. 3. 2022

doc. Ing. Petra Šimová, Ph.D.

Vedoucí katedry

Elektronicky schváleno dne 22. 3. 2022

prof. RNDr. Vladimír Bejček, CSc.

Děkan

V Praze dne 30. 03. 2022

## ČESTNÉ PROHLÁŠENÍ

Prohlašuji, že jsem bakalářskou práci na téma: „*Modelování lesních požárů v Kalifornii metodou geografické vážené regrese*“ vypracoval samostatně a citoval jsem všechny informační zdroje, které jsem v práci použil a které jsem rovněž uvedl na konci práce v seznamu použitých informačních zdrojů.

Jsem si vědom, že na moji bakalářskou práci se plně vztahuje zákon č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů, ve znění pozdějších předpisů, především ustanovení § 35 odst. 3 tohoto zákona, tj. o užití tohoto díla.

Jsem si vědom, že odevzdáním bakalářské práce souhlasím s jejím zveřejněním podle zákona č. 111/1998 Sb., o vysokých školách a o změně a doplnění dalších zákonů, ve znění pozdějších předpisů, a to i bez ohledu na výsledek její obhajoby.

Svým podpisem rovněž prohlašuji, že elektronická verze práce je totožná s verzí tištěnou a že s údaji uvedenými v práci bylo nakládáno v souvislosti s GDPR

V ..... dne .....

.....

*Dominik Šamanek*

## **Poděkování**

Chtěl bych poděkovat své vedoucí D. Sc. (Tech.) Olze Špatenkové za odborné vedení, trpělivost, věcné připomínky a cenné rady, kterými tuto práci po celou dobu směřovala k úspěšnému cíli. Dále bych chtěl poděkovat své rodině za trpělivost a podporu během studia. Dík patří také kolegům za pomoc s jazykovou korekturou.

# **Modelování lesních požárů v Kalifornii metodou geografické vážené regrese**

## **Abstrakt**

Bakalářská práce se zabývá problematikou modelování lesních požárů v Kalifornii metodou geografické vážené regrese. Hlavním cílem je vytvořit model rizika vzniku požárů a zjistit, zda jsou vlivy vysvětlujících proměnných prostorově proměnné.

V teoretické části práce představuje problematiku požárů a její pozitivní i negativní vlivy na krajinu. Popisuje metody používané k modelování požárů, nejenom v Kalifornii ale i ve světě a studuje faktory ovlivňující vznik požárů. Praktická část se věnuje tvorbě lokálního regresního modelu a porovnává ho s modelem globálním. Výsledky představuje formou tabulek parametrů a sérií map znázorňujících predikovanou pravděpodobnost vzniku požárů, rezidua a vlivy jednotlivých faktorů. Výsledky jsou podrobně interpretovány.

## **Klíčová slova**

lokální regrese, OLS, modelování rizika, příčiny požáru, AICc

# **Modeling of forest fires in California using the geographically weighted regression**

## **Abstract**

The bachelor thesis deals with the issue of modeling forest fires in California using the method of geographical weighted regression. The main goal is to create a fire risk model and find out whether the effects of explanatory variables are spatially variable.

The theoretical part of the thesis presents the issue of fires and its positive and negative effects on the landscape. It describes the methods used to model fires, not only in California but also in the world, and studies the factors influencing fires. The practical part deals with the creation of a local regression model and compares it with the global model. It presents the results in the form of parameter tables and a series of maps showing the predicted probability of fires, residues and the effects of individual factors. The results are interpreted in detail.

## **Keywords**

local regression, OLS, risk modeling, causes of fire, AICc

# Obsah

<b>1 Úvod</b> .....	<b>1</b>
<b>2 Cíl práce</b> .....	<b>3</b>
<b>3 Literární rešerše</b> .....	<b>4</b>
3.1 Kalifornie.....	4
3.1.1 Hlavní charakteristiky zájmové oblasti.....	4
3.2 Vlivy požárů na krajinu a vegetaci.....	4
3.2.1 Pozitivní vlivy .....	5
3.2.2 Negativní vlivy.....	6
3.3 Problematika požárů a jejich prevence.....	7
3.3.1 Metody používané k modelování vzniku požárů .....	9
3.3.2 Hlavní parametry ovlivňující požáry .....	11
3.3.3 Přírodní a člověkem způsobené požáry.....	12
<b>4 Metodika</b> .....	<b>14</b>
4.1 Geografická vážená regrese a lineární regrese .....	14
4.2 Data a lokalita.....	16
4.2.1 Příprava dat .....	17
4.2.2 Vstupní data .....	17
4.3 Zpracování a použité funkce .....	18
<b>5 Výsledky</b> .....	<b>21</b>
<b>6 Diskuze</b> .....	<b>29</b>
<b>7 Závěr</b> .....	<b>31</b>
<b>8 Seznam použitých zdrojů</b> .....	<b>32</b>
<b>9 Přílohy</b> .....	<b>39</b>



## Seznam použitých zkratek

AICc – Akaike Information Criterion – Informační kritérium Akaike

BEHAVE – Fire Behavior Prediction and Fuel Modeling System – Predikce chování požáru a systém modelování paliva

CFFDRS – Canadian Forest Fire Danger Rating System – Kanadský systém hodnocení nebezpečí lesních požárů

FARSITE – Fire Area Simulator – Simulátor požární oblasti

FBP – Canadian Forest Fire Behavior Prediction System – Kanadský systém předpovědi chování lesních požárů

FWI – Canadian Forest Fire Weather Index – Kanadský index požárního počasí

GWR – Geographically Weighted Regression – Geografická vážená regrese

NFDRS – The National Fire Danger Rating System – Národní systém hodnocení nebezpečí požáru

NFFL – National Forest Fire Laboratory – Národní laboratoř lesních požárů

NFMAS – The National Fire Management Analysis System – Národní analytický systém řízení požárů

OLS – Ordinary Least Squares regression – regresní metoda nejmenších čtverců

StdRes – Standardized Residuals – Standardní reziduály

USA – United States of America – Spojené státy americké

USD – United States Dollar – Americký dolar

WHR – Wildlife habitat relationship – Vztahy přírodních stanovišť

# 1 Úvod

Požáry v Kalifornii jsou jednou z nejčastěji řešených přírodních katastrof na světě. Každoročně o nich slyšíme v televizi, novinách, rádiích a sociálních médiích, a to většinou v období podzimu či léta. Jedná se o velice devastující přírodní jev, který má několik různých příčin. Jedná se buď o požáry přírodní nebo uměle založené ať již jako součástí protipožárního úsilí, zhářství nebo nešťastné náhody. Tato práce se zabývá požáry v období mezi roky 2000 až 2020. V tomto období bylo zjištěno, že 19 % požárů bylo přírodního charakteru, 52 % způsobeno člověkem, 9 % smíšeného charakteru a 20% neznámé příčiny. Člověkem způsobené požáry měly velmi rozdílné příčiny, těmi byly nedopalky od cigaret, ohniště, zhářství, elektrická vedení, auta, používání náradí v prostředí náchylné na vzplanutí (sváření, řezání, aj.), cvičení hasičů a také neuhlídané požáry řízeného vypalování či jiné. Zároveň se požáry lišily obdobími, ve kterém vznikaly. Během období od května do října bylo 6 129 požárů a po zbytek roku pouze 655 požárů. Podle těchto hodnot se dá mluvit o sezónních a mimo sezónních požárech. Důležité je i zmínit, že ne každý požár je katastrofou a destruktivním živlem, existují i „dobré“ požáry které jsou nedílnou součástí krajiny a v některých případech bez nich nemůže příroda existovat.

Roční škody této přírodní katastrofy dosahují až miliard USD. V roce 2018 přesáhly americké federální náklady na likvidaci požárů v divočině 3,1 miliardy dolarů, což z nich dělá historicky nejnákladnější požární sezónu v Kalifornii. V roce 2019 to činilo 1,6 miliard dolarů a v roce 2020 pak 2,3 miliard dolarů. Roční průměr federálních nákladů na potlačování požárů je 1,9 miliard dolarů za posledních 10 let (National Interagency Fire Center, 2020). Požáry jsou vysoce nákladné nejenom z pohledu prevence, případného potlačování a hašení požárů, ale i z hlediska škod na majetku. Prevencí můžeme docílit menších škod a nákladů, když budeme schopni požáry, jejich ohniska a příčiny predikovat. V dnešní době se vydává velké úsilí a finance na vytvoření modelů, jež by dokázaly predikovat kde je nejvyšší pravděpodobnost jeho vzniku.

Proto se v této práci budeme zaměřovat na jeden z modernějších přístupů k modelování vzniku požárů, a to pomocí Geografické vážené regrese. Tato regrese spočívá v predikování vzájemných vztahů proměnných v závislosti na poloze. Soustředíme se na procesy a příčiny vzniků požárů, jaké faktory je ovlivňují ve větší míře a budeme zkoumat odlišnosti modelu v závislosti na poloze. Model se bude porovnávat s globálním

modelem a zjišťovat jaké mezi nimi panují rozdíly a který z nich je použitelnější pro naši predikci.

## 2 Cíl práce

Práce se věnuje modelování rizika vzniku lesních požárů v Kalifornii za pomoci metody geografické vážené regrese (GWR). Práce je zaměřena na sledování požárů v letech 2000 až 2020.

Hlavním cílem je vytvořit geograficky vážený regresní model a porovnat jej s modelem globálním. Dílčími cíli jsou stanovení faktorů, které ovlivňují riziko vzniku požárů a kvantifikace tohoto vztahu.

Práce se zaměří na faktory, které lze považovat za neměnné v čase, jako je nadmořská výška, svažitost, vztahy mezi přírodními stanovišti, vzdálenost k zastavěným oblastem a zalesnění. Pro jejich vyjádření budou vyhledána vhodná data. Výsledky práce budou vhodně vyjádřeny pomocí tabulek a mapových výstupů a také budou podrobně interpretovány.

## **3 Literární rešerše**

### **3.1 Kalifornie**

#### **3.1.1 Hlavní charakteristiky zájmové oblasti**

Geomorfnní provincie představují přírodní útvary, v nichž jsou hranice zemských forem pozoruhodně konzistentní s hranicemi biologických společenstev. To znamená, že tvar Země ovlivňuje klima, a to ovlivňuje distribuci rostlin a zvířat (Schoenherr, 2017). Rozdělení Kalifornie není uniformní a každý vědec ji rozděluje podle trošku jiných kritérií. V roce 1983 bylo definováno 19 eko regionů od Roberta Baileyho. Tyto eko regiony byly definovány na základě geografie, klimatu a vegetace a jsou uspořádány hierarchicky do provincií. Bailey používá 50 kategorií k popisu distribuce kalifornských rostlin. Existují 3 hlavní floristické provincie, těmi jsou Kalifornie, Great Basin a Desert. Kalifornská provincie je primární skupinou rostlin a je výrazně kalifornská. Je velice dobře adaptovaná na požáry a sucho. Great Basin provincie v podstatě označuje vše na západ od pouští a zahrnuje tu část Kalifornie, která je hluboce ovlivněna klimatem podobným evropskému středozevnímu klimatu, charakterizovaným zimními srážkami a suchými léty. A Desert je extrémně suchá a písčná oblast kvůli nedostatku srážek, jenom rostliny silně přizpůsobené podmínkám zde dokážou přežít.

Hartwell Welsh v roce 1994 definoval 16 eko regionů (Welsh, 1994) a dělil celou oblast podle klimatu, dominantních půd, dominantní vegetace a druhotné vegetace. Kalifornii rozdělil na North Coast, Klamath, Cascade, Modoc Plateau, North Sierra, South Sierra, Mono-Inyo, Sacramento Valley, San Francisco Bay/Delta, San Joaquin Valley, Central Coast, South Coast, Transverse Range, Peninsular Range, Mojave Desert a Colorado Desert. (Welsh, 1994). Horská pásma rozprostírající se na délku Kalifornie tvoří významný blok proti zimním bouřím z Tichého oceánu. Od severu k jihu jsou to pohoří Cascade Mountains, Sierra Nevada, Transverse Ranges a Peninsular Ranges (Schoenherr, 2017).

#### **3.2 Vlivy požárů na krajinu a vegetaci**

Oheň nemusí být vždy „dobrá“ nebo „špatná“. Důležitými faktory k tomuto určení je kdy, kde a za jakých podmínek daný požár vznikl. V ekosystémech vysoce náchylných na požáry může požár přinést více negativních účinků. Na druhou stranu v ekosystémech, které jsou nakloněné k požárům (ekosystémy které se následkům požárů přizpůsobily) je

oheň nejenom ekologickým, ale i evolučním faktorem, jež udržuje rozmanitost ekosystémů, a proto jej nelze považovat za „špatný“ (Fidelis, 2020).

Účinky požárů na vegetaci nejsou ovlivněné požárem jako takovým, ale požárním režimem. Tím se myslí, ve kterém ročním období, jakou frekvencí, rozsahem, intenzitou či závažností dané místo hoří (Keeley et al., 2011). Pokud člověk začne měnit požární režim oblasti, může způsobit změnu role požárů z „dobrých“ na „špatné“. Lidé tento režim mohou negativně ovlivňovat dvěma způsoby. Prvním je že požáry jsou uměle zakládány (žhářství), druhým je potlačování přírodních požárů (Goldammer, 2021). Požáry založené člověkem během období sucha (období bez dlouhodobých dešťů), mohou vést k nekontrolovatelným požárům a ty mohou ovlivňovat lidské životy a mít katastrofální následky. Bohužel větší protipožární úsilí člověka, může vést ke změně vlastností ekosystémů a tím k intenzivnějším a závažnějším požárům (Fidelis et al., 2018).

Dopady požárů do značné míry závisí na vlastnostech daného požárů. Mezi tyto vlastnosti se řadí velikost, množství uvolněného tepla, trvání a intenzita. Větší a intenzivnější požáry jsou výsledky extrémnějších podmínek panujících v zasažené oblasti. Mezi ně patří vysoká dostupnost paliva, nízká vlhkost, vysoké teploty a vysoká rychlost větru. Kvůli tomu mají tyto požáry, na stejné celkové spálené ploše, větší dopady než požáry menších rozměrů (Hantson et al., 2015). Na konci období sucha dochází k výraznému nárůstu mrtvého paliva a tím ke zvýšení intenzity a závažnosti požárů. Požáry v ekosystémech náchylných k požárům na konci tohoto období tím pádem nejsou nic neobvyklého. Se začátkem období dešťů je vyšší pravděpodobnost výskytu blesků, čímž se přírodní požáry mohou rozšiřovat na velké plochy. V tomto období se obvykle začne mluvit o velkých lesních požárech v různých oblastech planety, jež spálí rozsáhlé oblasti a jsou považovány za přírodní katastrofu (Fidelis, 2020).

### **3.2.1 Pozitivní vlivy**

Oheň může mít velice pozitivní vliv na ekosystémy, jež jsou nakloněné k požárům, i jejich vegetaci. Přírodní požáry, které jsou hlavně způsobené úderem blesků nebo vulkanickou činností, se vyskytovaly na naší planetě od období Siluru již před 420 miliony lety (Fidelis et al., 2018). Důvodem k těmto prvním požárům bylo rozmnožování a rozšiřování většího množství vyšších cévnatých rostlin jako například *Hollandophyton colliculum* (Glasspool et al. 2004), které sloužily jako palivo.

Požáry se vyskytují přirozeně a mohou hrát důležitou roli. Obohacují půdu spalováním mrtvé nebo rozkládající se hmoty, odstraňují vegetaci sužovanou chorobami a škodlivým hmyzem (Melo, 2020). Odstraňování nadzemní biomasy a steliva přispívá k otevření prostoru ve vegetaci a ke změně mikroklimatických podmínek, které mohou ovlivňovat po požární regeneraci vegetace (Fidelis et al., 2012). Požáry a ohně formují vegetaci po celém světě, přispívají k diverzifikaci krytosemenných rostlin a ovlivňují evoluci a distribuci ekosystémů (Fidelis et al., 2018). Odstraňováním husté koruny a podrostů vznikají mezery, napomáhající slunečnímu záření dostat se k rostlinám na lesní půdě (Melo, 2020), a dávají příležitosti pro nové kolonie rostlin se usadit. Tyto vznikající mezery mají zásadní význam v několika ekosystémech, ty jsou na nich přímo závislé a vyžadují je pro udržitelnost biologické biodiverzity. V tomto případě jsou požáry nedílnou součástí, a přinášejí pozitivní efekt na shromáždění rostlinného společenství (Fidelis et al., 2020).

### **3.2.2 Negativní vlivy**

Oheň je obvykle označován jako něco špatného, co ničí, demoluje anebo dokonce zabíjí. Když se mluví o požárech a obzvláště o těch lesních, často jsou naznačena pouze negativní fakta, jako únik velkého množství oxidu uhličitého a jiných aerosolů do atmosféry (Schlosser et al., 2017), socioekonomické dopady, jako jsou lidské ztráty či škody na majetku (Gill et al., 2013).

Kouř a plynné částice z lesních požárů, a to včetně řízených vypalování, mají 2 hlavní negativní účinky. Prvním je ovlivňování atmosféry (ohřívání atmosféry) emisemi skleníkových plynů (Gill et al. 2013) jako například CO<sub>2</sub>, jenž je hlavním plynem uvolňovaným při hoření. V poslední době roste zájem o stanovení jeho účinků na vegetaci. Uvažuje se o CO<sub>2</sub> jako novém faktoru, který ovlivňuje vegetaci. Obzvláště pak jeho vlivy na přijímání vody, rychlosti fotosyntézy a využívání světla a živin vegetací. (Bond et al. 2003). Druhým negativním účinkem je ovlivňování lidského zdraví. Zejména množstvím kouře produkovaného nad citlivými oblastmi, kde se nachází lidská populace a důležité struktury. Dopady lze snížit zmenšením spálené plochy a použitím modelů rozptylování kouře a výběrem dnů pro řízené vypalování, kdy směr větru odvádí kouř pryč od lidí a objektů (Gill et al. 2013). Expozice komunitnímu kouři, v důsledku lesních požárů v divočině, byly spojeny se zvýšeným počtem hospitalizací na pohotovosti a v nemocnicích pro chronickou obstrukční plicní nemoc, bronchitidu, astma či bolest na hrudi (Mott et al. 2002).

Požáry vyskytující se v blízkosti městských oblastí ohrožují životy a majetek. Riziko, které představují podněcuje komunity k prevenci nebo snížení výsledných škod (Thomas et al. 2017). Primárním bezpečnostním problémem při požárech jsou životy civilistů, kteří se nachází v cestě požáru. Dle oficiálních zdrojů Kalifornského ministerstva lesnictví a požární ochrany (Cal Fire) jsou civilní oběti relativně nízké. Jedná se v průměru o 25 obětí za rok (mezi roky 2013-2020 viz. Příloha 1, kde je vidět i souhrn spálené půdy a zničených budov.). Druhým bezpečnostním problémem jsou škody na majetku, infrastruktury a samotných lesů. Škody způsobené lesními požáry v roce 2018 dosáhly celkové výše 148,5 (126,1–192,9) miliard USD (Americký dolar) (zhruba 1,5 % ročního hrubého domácího produktu Kalifornie), s 27,7 miliardami USD (19 %) v kapitálových ztrátách, 32,2 miliard USD (22 %) ve zdravotních nákladech a 88,6 miliard USD (59 %) nepřímých ztrát spojených s průmyslovým odvětvím a potlačováním požáru (Wang et al. 2020).

Konkrétně největším požárem na rozlohu v historii Kalifornie byl požár The August Complex. Jedná se o komplexní požár sestávající z 38 menších požárů, jež se najednou rozhořely 16. – 17. srpna 2020 a zasáhly oblast Coast Range v Severní Kalifornii. Hlavně v 7 krajích a to: Mendocino, Humboldt, Trinity, Tehama, Glenn, Lake a Colusa. Dle oficiálních zdrojů Cal Fire byl požár založen přírodně a celkově bylo spáleno 1 032 648 akrů půdy (4 180 km<sup>2</sup>) (fire.ca.gov, 2022) což odpovídá přibližně 1% Kalifornské půdy. V průběhu tohoto požárů zemřela 1 osoba a bylo zničeno 935 budov. Celkové škody činily přes 300 milionu USD a z toho 115 ,5 miliónů USD padlo na potlačování tohoto požáru (fire.ca.gov, 2022).

Naproti tomu nejsmrtejnějším a zároveň nejdražším požárem byl Camp Fire. Vypukl 8. listopadu 2018 a zasáhl oblast kraje Butte, kde spálil 153 336 akrů (621 km<sup>2</sup>). Nejsmrtejnějším požárem se stal poté co mu za obět' padlo 85 lidí a 3 zranění a současně přitom bylo zničeno 18 804 budov. Celkově tento požár stál Kalifornii 16.5 miliard USD (fire.ca.gov, 2022).

### **3.3 Problematika požárů a jejich prevence**

Na rozdíl od jiných přírodních nebezpečí, jako zemětřesení nebo sopečná činnost, jsou lesní požáry vnímány jako riziko, kterému se lze vyhnout. Způsobují rozsáhlé škody a na jejich přípravu a boj se vynakládají značné finanční prostředky (Brillinger et al., 2006), zejména tomu tak je ve vyspělejších zemích (Doerr & Santín, 2016). Protipožární ochrana



zahrnuje všechny činnosti související s kontrolou a konečným uhašením požáru (Alexander, 2000), ale i případná mitigace následků požárů. Odhadované federální náklady za protipožární úsilí činily v roce 2019-2020 691 milionů dolarů (USD), v roce 2020-2021 to bylo 1,76 miliard dolarů (USD) a 2021-2022 pak 1,176 miliard dolarů (USD) (fire.ca.gov, 2022). Finanční náklady jsou jedním z důvodů proč se snaží Kalifornského ministerstva lesnictví a požární ochrany vytvořit model pro odhalování rizik vzniku požárů.

Prevence požárů začíná pochopením toho, kdy a kde je nejpravděpodobnější výskyt požáru a jak daný požár započal. Podle této logiky mohou být strategie požární prevence navrženy tak, aby se přímo zaměřovaly na zdroj problému (Hesseln, 2018). Náklady spojené s prevencí a potlačováním požárů zatěžují veřejnou správu půdy po finanční stránce. Proto jí zbývá malé množství finančních zdrojů na jiné činnosti spojené se správným fungováním lesa. Mezi ně patří i zakládání kontrolovaných požárů pro udržování ekologických a evolučních faktorů (Dombeck et al. 2004). Proto je tu snaha o snížení pravděpodobnosti vzniku požárů a mitigaci jejich negativních účinků. Tyto snahy zahrnují rychlou detekci požárů, lepší mapování, využití dat pro rozhodování, zlepšení komunikace a použití nových hasících přístrojů a nástrojů, buď pro rychlejší nebo efektivnější potlačení (Finney, 2021). Historie požárů ukazuje, že velká část severovýchodní Kalifornie byla bez větších požárů i po dobu 75 let, především díky velmi úspěšnému potlačování a prevenci požárů, i když tato oblast byla známá velkými a častými požáry (Stephens & Collins, 2004). Avšak toto období mělo za následek abnormální nahromadění paliva, což přispělo k neobvykle těžkým a velkým požárům, které pokrývaly mimořádně rozsáhlou oblast (Keeley & Syphard, 2019).

Největším problémem v Kalifornii jsou požáry na rozhraní mezi městy a divočinou. Tyto požáry devastují komunity nejenom v Kalifornii ale napříč celými Spojenými státy. Navzdory známým rizikům se lidé stále více stěhují do oblastí s vysokou mírou rizika vzniku požárů. Hlavním důvodem je hledání přírodnějších podmínek k bydlení jako jsou otevřený prostor, rekreační příležitosti, větší volnost a jiné. Tento problém je obzvláště zřejmý v Kalifornii kde se přibližně pět milionů domů nachází na tomto rozhraní (Theobald & Romme, 2007). Toto číslo je největší v celých USA (Spojené státy Americké) a očekává se, že se bude zvyšovat. Tento trend je všude ve světě umocněný dlouhodobými ekonomickými podmínkami, jako je klesající cena venkovských komodit (Stephens et al., 2009).

### 3.3.1 Metody používané k modelování vzniku požárů

Modely požárů jsou často neformálně označovány jako modely chování ohně, modely efektů ohně nebo modely kouře. Jedním z nejpoužívanějších modelů požáru je Rothermelův (1972), který simuluje šíření požáru v povrchových palivech. Byl vyvinut jako výsledek plánu z roku 1968 pro kompletní systém hodnocení požárního nebezpečí. Výsledkem byl model šíření požáru a národní systém hodnocení nebezpečí požáru (NFDRS) (Arroyo et al. 2008). Tento model je základem mnoha systémů pro podporu rozhodování v Severní Americe, včetně NFDRS, BEHAVE (Predikce chování požáru a systém modelování paliva), FARSITE (Simulátor požární oblasti) a Národní analytický systém řízení požárů (NFMAS) (Lundgren et al., 1995). NFDRS představuje širokou stupnici systému nebezpečí požárů, jedná se o primárně sezónní systém počasí. Tento systém je závislý na sadě záznamů počasí, ze kterých se mají vytvořit podmínky toho dne. Ty se společně s palivovým modelem NFDRS používají k reprezentaci každodenních sezónních trendů nebezpečí požárů nebo také k reprezentaci požárního potenciálu pro velké oblasti (Deeming et al., 1977). Systém BEHAVE používá jinou klasifikaci typu paliva, známou jako NFFL (Laboratoř severních lesních požárů). Ten rozděluje paliva do čtyř hlavních skupin vegetace, těmi jsou rostlinná paliva, křoviny, mrtvé listy pod stromy a zbytky s bazálním akumulacním materiálem. Systém FARSITE využívá stejnou klasifikaci jako NFFL. Tento systém podpory rozhodování, jež vyvinul Finney (1998), zahrnuje modely pro korunové ohně, jejich chování, a i povrchové modely paliva. Z toho důvodu vyžaduje specifické informace o korunách stromů jako jsou procentuální pokrytí listoví, výšku klenby větví, výšku koruny a objem koruny (Arroyo et al., 2008). NFMAS je model, který definuje optimální předběžnou organizaci potlačení požárů pro plánovací jednotky a pomáhá místním manažerům s rozhodováním o požárním a územním řízení oblastí. Implementuje analýzu nákladů a přínosů potlačování požárů, a i vytváření požárů na pozemcích národních lesů (Lundgren et al. 1995).

V Austrálii jsou dva nejpoužívanější modely. Oba systémy byly navrženy Alanem McArthurům v 60. letech minulého století. Prvním je McArthurův systém hodnocení nebezpečí lesního požáru, který kombinuje míru sucha, srážek, výparů, rychlosti větru, teploty a vlhkosti vzduchu. Pohybuje se v rozmezí od 1 do 100 (ve stepích do 150) a jeho výsledky se člení do 6 stupňů, od nejnižšího stupně „Velmi nepravděpodobný vznik požáru“ až po „Katastrofická možnost vzniku požáru a jeho šíření“. Druhým je McArthurův systém hodnocení nebezpečí požáru travnaté půdy. Oba systémy jsou

založené na způsobech používaných v USA v 50. letech minulého století a jedná se o modely odhadu nebezpečí požárů v typech travních a lesních porostů (Arroyo et al. 2008).

Aktuálním systémem používaným v Kanadě je Kanadský systém hodnocení nebezpečí lesních požárů (CFFDRS) tvořený ze dvou hlavních subsystémů, které se používají v celém státě již několik let. Prvním je Kanadský index požárního počasí (FWI) a druhým je systém Kanadský systém předpovědi chování lesních požárů (FBP) (van Wagner, 1987). Systém FBP je založen na jednoduchých matematických modelech a částečně také na fyzikálních a experimentálních modelech. Poskytuje kvantitativní odhady potenciální rychlosti šíření požárů, spotřeby paliva, intenzity a také popis požáru. S pomocí eliptického modelu růstu požáru poskytuje systém odhad oblasti požárů, jeho obvodu, rychlosti růstu a chování požárů v čele, na bocích, a i v zadní části požáru. Modely pro chování požárů a spotřeby paliva jsou v tomto systému odvozeny z databáze více než 400 experimentálních, normálních a předepsaných požárů (Arroyo et al. 2008).

Porovnáním modelů OLS (Ordinary Least Square) a GWR a možnosti využívání GWR k modelování požárů se zajímaly jiné studie, příkladem je práce od autorů Koutsias, Martínez, Chuvieco a Allgöwer. Ti v roce 2005 vydali „Modelling Wildland Fire Occurrence in Southern Europe by a Geographically Weighted Regression Approach“. Využité byly socioekonomické a demografické ukazatele společně s proměnnými popisující statistiky krajinného pokryvu (využití půdy). V roce 1960 bylo stanoveno celkem 77 proměnných v jižní Evropě, včetně Portugalska, Španělska, jižní Francie, jihovýchodního Švýcarska, Itálie a Řecka. Dále tam vstupovaly vypočtené rozdíly některých proměnných, které ukazovaly změny v populačních charakteristikách a krajinném pokryvu/využití. Jako závislá proměnná byl uveden počet lesních požárů, ke kterým došlo v období 1992-2000. Podle studie GWR poskytla výrazně lepší výsledky než globální regresní model, protože se rozptýl vysvětlené závislé proměnné zvýšil z 53 % na 68,65 %. Zároveň model GWR zlepšil odchylku z 178,35 na 116,54. GWR také úspěšně klasifikovala 84,97 % pozorování, což je výrazně více než 66 % běžného globálního logistického režimu. GWR se podle nich zdá být cenným přístupem pro zkoumání a modelování nestacionárních vztahů mezi odezvou a vysvětlujícími proměnnými, a tak lépe porozumět prostorovým procesům při výskytu divokých požárů (Koutsias et al., 2005).

### 3.3.2 Hlavní parametry ovlivňující požáry

Ve studii od autorů Kanga, Sharma, Pandey, Nathawat a Sharma z roku 2013 bylo provedeno mapování rizik lesních požárů za pomoci dálkového průzkumu Země a GIS technologií. Toto mapování zahrnovalo faktory jako svažitost, rozlohu, typy lesů a jejich hustotu, využití půdy a vzdálenost od zástavby (Kanga et al., 2013).

Znalosti podmínek a typů paliva jsou kritické pro řízení a odhalování lesních požárů, protože palivo představuje primární složku rizika požárů (Chuvieco et al., 2004). Tyto podmínky jsou obvykle komplikované a ztěžka se popisují. Na jejich základě vznikají palivové mapy a ty jsou nezbytnou součástí vstupů do programů, jež simulují chování požárů. Palivové mapy lze používat v různých prostorových a časových měřítkách, na jejichž základě se dělají strategická plánování. Ta vyžadují mapy velkých měřítek, zatímco pro regionální požární management se mohou vyžadovat podrobnější mapy (Pausas & Vallejo, 1999).

Taktéž nadmořská výška, směr a prudkost svahů hrají důležitou roli při šíření požárů. Typicky jsou jižní a jihozápadní svahy vystaveny přímému slunečnímu svitu, a tak jsou náchylnější ke snadnému vznícení ve srovnání se severními a severovýchodními svahy. V případě sklonu a svažitosti se oheň šíří rychleji směrem do kopce při vyšším sklonu a pomaleji z kopce při vyrovnanější svažitosti (Rothermel & Richard, 1972). Obecně platí, že oheň hořící do svahu, podporovaný větrem, ukazuje nejvyšší míru šíření, největší potenciál škod a největší potíže s jeho zvládnutím (Weise et al., 1997).

Samozřejmě se nesmí opomenout již zmíněný vítr, ten se často prezentuje jako jeden z nejdůležitějších faktorů ovlivňující lesní požáry. Důležitými jsou hlavně jeho rychlost a směr, ty se mění v čase řádově v hodinách, minutách, a dokonce sekundách. Vítr je v rámci lesních požárů silně ovlivňován nejenom terénem ale i vegetací. V hustší a vyšší vegetaci se vítr šíří pomaleji než při nízké a řídké vegetaci. Kromě horizontálních změn napříč krajinou se vítr mění i po vertikální ose, kde s rostoucí výškou fouká rychleji (Andrews, 2012).

Dalšími neopomenutelnými faktory jsou počasí, atmosférický tlak a klima, včetně teploty a srážek, ty jsou kritickými aspekty při požárech. Při testování citlivosti modelu krajinných požárů na změny klimatu zjistili Cary et al. (2006), že spálená půda se drasticky zvětšuje s vyšší teplotou. Tento jev je očekávaný a celkem předvídatelný, proto není překvapivé, že největší nárůst spálené plochy byl při velice teplých a suchých scénářích. Čím větší bylo teplo a sucho tím větší plochu požáry spálily. Avšak tento jev

byl pozorovaný i při zvýšených srážkách (i přes zvýšené srážky a teploty se spálená plocha zvětšovala). Srážky mají také velice důležitý vliv na aktivitu a šíření požárů, ale zjistilo se, že samotné načasování srážek během období požárů je obvykle důležitějším faktorem nežli jejich samotné množství (Flannigan et al., 2013).

Požární trojúhelník se běžně používá k ilustraci základních principů hašení požáru. Chcete-li zastavit volně hořící oheň, musíte buď: odstranit palivo před šířící se spalovací zónou, nebo snížit teplotu hořících paliv, nebo vyloučit kyslík z dosahu spalovací zóny udušením (Alexander, 2000).

### **3.3.3 Přírodní a člověkem způsobené požáry**

Požáry můžeme rozdělit do několika kategorií podle způsobu jejich vzniku. Nejzákladnějšími kategoriemi jsou požáry založené člověkem a požáry přírodní. Většina přirozeně způsobených požárů je způsobena suchým bleskem, kdy buď malé nebo žádné množství srážek doprovází bouřlivé počasí (Ganteaume et al., 2008). V závislosti na okolnostech mohou být také vulkanické nebo třeba meteoritické. Požáry způsobené blesky představují 16 % všech lesních požárů v kontinentálních Spojených státech v období 1992–2013 a tvoří 56 % z celkové výměry spálené půdy (Balch et al., 2017). Podobně tomu je i v australské Victorii, kde požáry založené blesky byly zodpovědnými za 70 % spálené půdy v období 1973–2014 přestože tvoří pouze 11 % všech požárů (Nicholas et al., 2018). Na základě těchto údajů by se dalo říct, že přírodní požáry způsobené blesky mají daleko horší průběh, protože na rozdíl od jiných zdrojů vznícení se často vyskytují na odlehlých a nepřístupných místech a jsou zvláště obtížné na detekci, a i na jejich následné potlačení (Flannigan & Wotton, 1991). Výskyt blesků, vlastnosti a vlhkost paliva určují, zda dojde ke vznícení a daný požár přežije až do jeho zjištění. Aby blesk dokázal založit požár je nutná přítomnost vhodného paliva, v takovém stavu, kdy se může vznítit, shořet a nachází se ho tam dostatečné množství, aby daný požár uživilo. Také záleží na nadmořské výšce, ta může způsobit nucenou konvekci atmosférického proudění, která vede k úderům blesků (Duff et al., 2017). Taktéž individuální bouřky s blesky mohou mít za následek větší počet požárů seskupených v jednom území a ty mohou snadno předčít snahy o jejich potlačení (Podur et al., 2003) a tak se požár rozhoří a spálí neúměrně velké plochy.

Požáry způsobené lidskou činností jsou také zdrojem velkých požárů nejenom v USA (Nagy et al., 2018), ale i celosvětově (Martínez et al. 2009), to zahrnuje jakýkoli lesní požár způsobený přímým nebo nepřímým antropogenním původem (Ganteaume et al.,

2008). Požáry způsobené lidskou činností mohou být náhodné, úmyslné (žhářství) nebo z nedbalosti. Náhodné jsou požáry, které vzniknou bez přímého přičinění a čirou náhodou. Požáry z nedbalosti jsou neúmyslně a nepřímo způsobeny lidmi, nesouvisí ani s vůlí, ani s nedbalostí ale spíše s neštěstím (Ganteaume et al., 2008). Úmyslné jsou úmyslně způsobeny lidmi. Tyto požáry mají obvykle za následek větší spálenou plochu než ty z nedbalosti (Ganteaume & Jappiot, 2013). Mnoho požárů způsobených člověkem souviselo s konkrétními lidskými činnostmi, včetně stavby silnic, pasení ovcí, kempování a bydlením, ty způsobují nové vzorce vznícení, které se liší od vzorů generovaných vzníceními způsobenými bleskem (Syphard et al. 2007). Zatímco ostatní proměnné související s nebezpečím požáru, jako je teplota nebo relativní vlhkost se běžně generují, časová a prostorová data potřebná k hodnocení lidského rizika prostě neexistují nebo jsou zřídka k dispozici (Martell et al., 1987), čili se dá těžko určit kde ovlivňují nebo neovlivňují krajinu a jakou intenzitou. Avšak lidské vlivy na výskyt požárů byly studovány pouze po regionální měřítku (menší oblasti), ale jak se liší napříč USA známo není. Porozumění vztahů mezi lidmi a požáry na národní úrovni je důležité, jelikož existuje silný vztah mezi lidským rozvojem a požáry. Lidské faktory se dají snadněji ovlivňovat politicky a opatřeními, než jiné faktory jako je třeba klima (Hawbaker et al. 2013)

## 4 Metodika

Praktická část studie vysvětlí a popíše rizika vzniku požárů pomocí metody geografické vážené regrese. Zároveň popíše a vysvětlí její výsledky, přesnost a porovná jí s lineární regresí OLS.

### 4.1 Geografická vážená regrese a lineární regrese

Termín regrese a metody zkoumání vztahů mezi dvěma proměnnými sahají až do roku 1908, kdy jej poprvé zavedl Francis Galton. Jedním z jeho pozorování bylo, že děti vysokých rodičů jsou vyšší než průměrné děti, ale ne tak vysoké jako jejich rodiče. Tato „regrese k průměrnosti“ dala těmto statistickým metodám jméno (Yan & Su, 2009). Regrese zahrnuje širokou škálu metod používaných k modelování vztahů mezi závislou proměnnou a množinou jedné nebo více nezávislých proměnných. Závislá proměnná je také známá jako proměnná  $y$  nebo regressand. Nezávislá proměnná je známá jako proměnná  $x$ , predikovaná proměnná nebo regresor (Charlton et al. 2009). Je známo že lineární regrese poskytuje nejjednodušší formu modelování regresní funkce jako lineární kombinaci prediktorů. Je velice populární, a to z několika důvodů. Hlavním je snadná interpretovatelnost parametrů modelu díky jejímu lineárnímu tvaru. Taktéž teorie lineárních modelů je dobře zavedená s matematickou elegancí a výpočtem (Su et al., 2012). Regrese je vyjádřena jako rovnice (viz. Rovnice 1).

$$y_i = \beta_0 + \beta_1 x_i + \varepsilon_i \quad \text{for } i = 1 \dots n$$

*Rovnice 1: Regresní rovnice*

V této rovnici  $y_i$  je proměnná, zde měřená v nějakém místě  $i$ ,  $x_i$  je nezávislá proměnná,  $\varepsilon_i$  představuje chybovost v rámci statistického modelu a  $\beta_0$  a  $\beta_1$  jsou parametry. Nejoblíbenější metodou pro odhad  $\beta$  je metoda nejmenších čtverců. Ta minimalizuje vzdálenost od pozorovaného jevu na předpokládané hodnoty tak že hledá odhady  $\beta_0$  a  $\beta_1$  takové, aby součet druhé mocniny vzdálenosti od skutečné odezvy  $y_i$  a předpokládané odezvy  $\hat{y}_i = \beta_0 + \beta_1 x_i$  dosáhly minima ze všech možných voleb regresního koeficientu (Yan & Su, 2009). Metoda OLS (metoda nejmenších čtverců) je nejznámější z regresních technik. Je také výchozím bodem pro všechny prostorové regresní analýzy. Poskytuje globální model proměnné nebo procesu, který se snažíte pochopit nebo předpovědět, vytváří jedinou regresní rovnici reprezentující tento proces. Výstup generovaný z nástroje OLS zahrnuje třídu výstupních prvků symbolizovanou pomocí reziduí OLS, statistických výsledků a diagnostiky (pro.arcgis.com, 2022).

Prostorová data obsahují informace nejenom o poloze ale také informace o atributech. Stále více a častěji se uznávalo, že prostorová data mají zvláštní vlastnosti a ty je odlišují od aspatialních (neprostorových) dat. Prostorová data téměř nevyhnutelně vykazují určitou formu prostorové závislosti na sobě, přičemž pozorovaná místa těsné blízkosti mívají podobnější atributy než místa od sebe vzdálenější. Nevýhodou je, že to má tendenci zneplatnit předpoklad nezávislosti chybovosti. Datové body, které se nacházejí blízko regresivního bodu, mají vysokou váhu, zatímco datové body vzdálenější mají váhu nižší. To znamená, že procesy generující pozorované atributy se většinou v prostoru liší, než aby byly konstantní, jak se předpokládalo při používání většiny tradičních typů statistické analýzy, a proto vyžadují vývoj specializovaných statistických technik (Fotheringham et al. 2009). Geografická vážená regrese (GWR) je forma prostorové analýzy představená v roce 1996 v geografické literatuře od autorů Fotheringham, Brunson a Charlton v „Geographically weighted regression: a method for exploring spatial nonstationarity“ čerpající ze statistických přístupů pro aplikace prokládání křivek a vyhlazování. Metoda funguje na základě jednoduché, ale výkonné myšlenky odhadu místních modelů pomocí podmnožin pozorování, jelikož dle Fotheringham et al. (2009) se zdá rozumné předpokládat, že by mohly existovat rozdíly ve vztazích v prostoru. To znamená, že se zaměřují na příčiny a důvody v jednotlivých bodech pozorování. Od svého zavedení GWR rychle upoutala pozornost mnoha lidí nejenom v geografii ale i dalších oblastech pro svůj potenciál zkoumat nestacionární vztahy v regresní analýze (Páez & Wheeler, 2009). Geograficky vážená verze regresního modelu je popsána pomocí rovnice (viz. Rovnice 2),

$$y_i = \beta_{0i} + \beta_{1i}x_{1i} + \beta_{2i}x_{2i} + \dots + \beta_{ni}x_{ni} + \varepsilon_i$$

*Rovnice 2: Rovnice geografické vážené regrese*

kde  $i$  se odkazuje na místo, kde se měří údaje o  $y$  a  $x$  a kde se získávají místní odhady parametrů. Odhad pro parametry je potom vidět v rovnici níže (viz. Rovnice 3),

$$\beta'(i) = (X^T W(i) X)^{-1} X^T W(i) Y$$

*Rovnice 3: Rovnice odhadu parametrů v GWR*

kde  $W(i)$  je matice vah specifických pro umístění  $i$  tak, že pozorování blíže k  $i$  mají větší váhu než pozorování vzdálenější (Fotheringham et al. 2009). Váhová matice se změní pokaždé, když se změní regresní bod. GWR jako výstupy vytváří odhady parametrů a jejich související standardní chyby v jednotlivých regresních bodech. Pokud jsou regresní body stejné jako body vzorku, pak GWR vytvoří předpovědi pro závisle proměnnou



(proložené hodnoty), rezidua a standardizované zbytky. Některé implementace také vydávají místní  $R^2$  hodnoty a vliv statistiky na matici (Charlton et al., 2009).  $R^2$  je statistická míra, která představuje podíl rozptylu pro závisle proměnnou, který je vysvětlen nezávislou proměnnou nebo proměnnými v regresním modelu. Je to číslo 0-1 a vyjadřuje, kolik procent rozptylu model řeší. Zbytek rozptylu je dán něčím, co ten model nevidí. Pokud je tato hodnota vyšší u GWR, než u OLS tak v těchto místech je model GWR lepší. Dalším výsledkem jsou hodnoty AICc, (Akaike Information Criterion) tato hodnota poskytuje odhad ztracených informací, když je k reprezentaci procesu generování dat, použit specifický model. Jedná se o měřítko výkonu modelu a lze jej použít k porovnání regresních modelů. Vezmeme-li v úvahu složitost modelu, model s nižší hodnotou AICc lépe odpovídá pozorovaným datům. Čím nižší je toto číslo, tím méně informací model ztratil a jeho kvalita je vyšší. Hodnoty T jsou odhad parametru dělený standardní chybou, ukazují na sílu vztahu mezi vstupy a závislou proměnnou a kde se tyto vztahy vyskytují. Hodnoty vyšší než 1,96 pro 95 % vyšší než 2.58 pro 99 % intervalu spolehlivosti. StdRes (Standardized Residuals) je měřítko síly rozdílu mezi pozorovanými a očekávanými hodnotami. Když se porovnávají buňky, umožňuje snadno zjistit, které buňky přispívají k hodnotě nejvíce a které nejméně, a to buď podhodnocováním nebo nadhodnocováním.

## 4.2 Data a lokalita

Obrovskou výhodou práce, která se zabývá oblastí Kalifornie, je otevřenost USA a jejich dat. Obzvláště patrné je to v Kalifornii, při snaze o získání dat o požárech a oblasti. Většina dat, jež byla použita v této práci pochází z oficiálních stránek Kalifornie na stránce Fire.ca.gov. WHR a nadmořská výška Kalifornie jsou data z databasin.org. Elevation model (nadmořská výška) pochází od autorky Wendy Peterman, která je půdním vědcem z US Forest Service a WHR je od Amerického ústavu ochrany přírody (CBI).

Kalifornie je státem patřícím do Spojených států amerických, nacházející se na západním pobřeží. Jejími sousedními státy jsou Oregon, Nevada, Arizona, na jihu mexický stát Baja California a její západní hranici tvoří Tichý oceán. Kalifornie je se svojí rozlohou 403 466.3 km<sup>2</sup> (Census.gov, 2021) třetím největším státem USA. Zároveň je nejlidnatějším státem s 39 512 223 obyvatel (Census.gov, 2021) a zemědělsky nejproduktivnějším státem Spojených států. (Pagán et al., 2016). Pobřeží Kalifornie s Tichým mořem se táhne 2 034 kilometrů od Oregonu po Mexiko. Kalifornie má nejvyšší i nejnižší bod z celé

pevninské části USA. Nejvyšším bodem je hora Mount Whitney ve střední Kalifornii, jež je vysoká 4 418 metrů a nejnižším je Badwater Basin v Death Valley 86 metrů pod hladinou moře. Kalifornie je stát s mnoha krajinnými prvky. Západní hranici Kalifornie tvoří pobřeží a ostrovy. Hory, údolí a pouště vyplňují zbytek tohoto dlouhého úzkého státu (Glaser J., 2003).

#### **4.2.1 Příprava dat**

V prvním kroku byla nutná agregace a úprava dat. Data použitá pro požáry vycházela z datové sady Fire perimeters throught 2020, zahrnující požáry dřevin o rozloze 10 akrů nebo více, požáry křovin 30 akrů a více a požáry trávy 300 akrů nebo více. Těchto požárů obsahuje datová sada 21 318 mezi roku 1878 až 2020. Pro tuto studii byly využity pouze roky 2000 až 2020. Po exportování všech požárů pomocí SQL zbylo 6 836 požárů v tomto období. Následné rozdělení požárů na jednotlivé roky a na požáry sezónní (1. května až 31. října) a mimo sezónní požáry (1. listopadu až 30. dubna) v každém roku. Nakonec proběhlo pomocí funkce merge pospojování všech sezónních požárů do samotné datové sady a s ní se následně pracovalo.

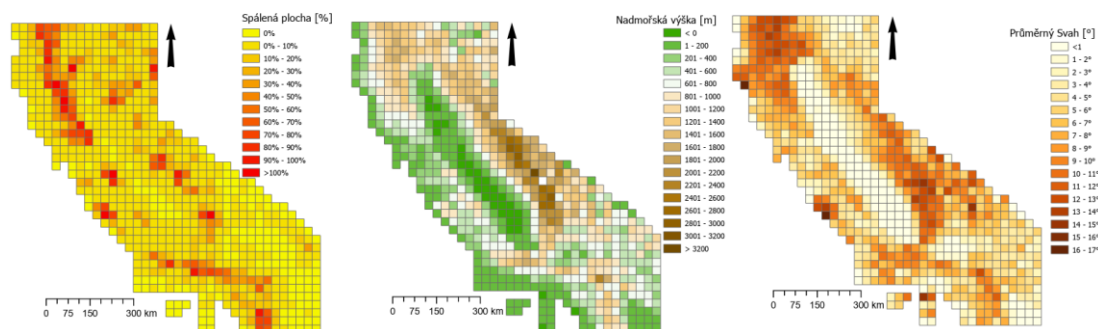
Dále bylo potřeba upravit datovou sadu WHR. Datová sada WHR obsahuje 58 přírodních stanovišť, ale vzhledem k datům bylo nutné zobecnění této sady na 11 stanovišť a těmi jsou křoviny, louky, stromy listnaté, stromy smíšené, stromy jehličnaté (všechny tři myšlené jako lesy), vegetace vyschlá, vegetace zavodněná, orná půda, holá půda, říční krajina a užitné plochy (spojená vrstva vinic a pastvin). Za toto zobecnění mohlo velké množství nulových hodnot, kvůli kterým nemohla proběhnout GWR. WHR je jedna vrstva, která pokrývá celou Kalifornii. Proto v místě, kde se nachází 1 stanoviště nemůže být logicky jiné, a tak vzniká velké množství nulových hodnot. To přestalo platit při zvětšování velikosti fishnetu a průměrování.

Naposledy se upravovala a používala datová sada Elevation (nadmořská výška), ta se reklasifikovala po 200 m. n. m a nabývala hodnot od menší než 0 až po větší než 3400, z této vrstvy vznikla dále vrstva Slope (svažitost).

#### **4.2.2 Vstupní data**

Na obrázku 1 jsou vidět příklady vstupních dat, jež vstupují do GWR, těmi jsou vlevo Průměrná spálená plocha mezi roky 2000-2020 uprostřed Průměrná nadmořská výška a vpravo Průměrná svažitost. Dalšími daty vstupujícími do GWR jsou Procentuální plocha zastoupení křovin, Procentuální zastoupení luk, Procentuální zastoupení listnatých lesů,

Procentuální zastoupení smíšených lesů, Procentuální zastoupení jehličnatých lesů, Procentuální zastoupení vyschlé vegetace, Procentuální zastoupení zavodněné vegetace, Procentuální zastoupení orné půdy, Procentuální zastoupení holé půdy, Procentuální zastoupení říční krajiny, Procentuální zastoupení zastavěné oblasti a Procentuální zalesnění oblastí (viz. Příloha 2 a 3).



Obrázek 1: Příklady vstupních vrstev použitých při GWR

### 4.3 Zpracování a použité funkce

Studie je zpracovaná v editačním prostředí ESRI, v programu ArcGIS Pro za pomoci různých funkcí vestavěných v možnostech programu. Byl použit souřadnicový systém WGS 1984 (4326). Všechny vstupní vrstvy do GWR byly v polygonech, všechny vrstvy v jiném formátu se převáděly pomocí funkce Raster to polygon.

Funkce Surface parameters ze sady Spatial analyst určuje parametry povrchu rastru, jako je poměr stran, sklon a zakřivení. Výstupní parametry se vypočítávají buňku po buňce, přizpůsobením místního povrchu kolem cílové buňky. Za pomoci této funkce byla vytvořena vrstva obsahující v buňkách rastrů odpovídající hodnotu svažitosti (pro.arcgis.com, 2022).

Funkce Slope ze sady Spatial Analyst identifikuje sklon (gradient nebo strmost) z každé buňky rastru. využívá ke zpracování dat oblast buněk 3 x 3. Pokud jsou uvnitř pozorované buňky NoData, výstupem pro tuto oblast bude NoData. Z osmi buněk sousedících buněk tento nástroj vyžaduje, aby alespoň sedm z nich mělo platné hodnoty. Pokud existuje méně než sedm platných buněk, výpočet se neprovede a výstupem v této buňce bude NoData. Díky této funkci a funkci Reclassify se vytvořila vrstva průměrných svažitostí od 0° do 17° z vrstvy elevation (pro.arcgis.com, 2022).

Funkce Create fishnet ze sady Data management vytváří pravidelnou síť obdélníkových buněk. Ty mohou být prvky linií nebo polygonů. Zájmovým územím studie je Kalifornie, která se rozdělila pomocí fishnetu na stejné velké díly po 597,66 km<sup>2</sup>. Strany tohoto

obdélníku jsou 27,76 x 21,57 km<sup>2</sup>, důvodem k takto velkému rozdělení území je akceptovatelnost GWR. Během studie bylo zjištěno, že GWR nesnese velké množství nulových hodnot, a tak se fishnet musel zvětšovat do doby, než funkce dokázala data akceptovat (pro.arcgis.com, 2022).

Funkce Summarize Within ze sady Analysis překrývá vrstvu polygonu jinou vrstvou, aby se shrnul počet bodů, délka čar nebo plocha polygonů v rámci každého polygonu a vypočítala se statistika pole atributů o těchto prvcích. Summarize Within se dá představit tak, že se vezmou dvě vrstvy, vstupní polygony a vstupní souhrnné prvky, a naskládají se na sebe. Po naskládání těchto vrstev se nahlédne shora a spočítají se číselné vstupní souhrnné prvky, jež spadají do vstupního polygonu. Nejen, že se může spočítat počet funkcí, ale i jednoduché statistiky o attributech. Mezi ně patří součet, průměr, minimum, maximum a další. Pomocí této funkce se překryli všechny nutné vrstvy přes Fishnet. Tím vznikla jediná polygonová vrstva, kde v každé cell (obdélníku fishnetu) se nacházely průměrné plochy všech pozorovaných jevů (pro.arcgis.com, 2022).

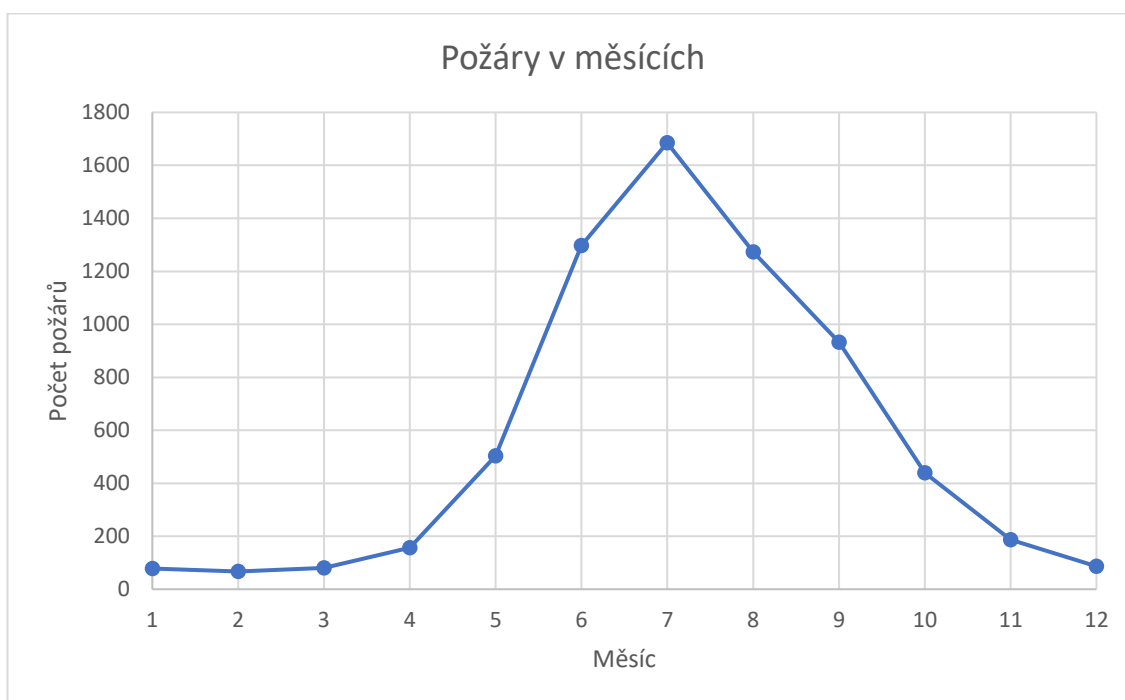
Funkce Geographically Weighted Regression (GWR) ze sady Spatial Statistics provádí geograficky váženou regresi (GWR), místní formu lineární regrese používanou k modelování prostorově proměnných vztahů. GWR vytváří samostatnou rovnici pro každý prvek v datové sadě zahrnující závislé a vysvětlující proměnné prvků v rámci každého cílového prvku. Tvar a rozsah šířky pásma závisí na uživatelském vstupu, a to buď Kernel type, Bandwidth method, Distance nebo Number of neighbors. V této studii byla použita metoda Number of neighbors s nastavením nejmenšího počtu sousedů 24 a největšího na 1000, aby tato funkce počítala s co největším množstvím sousedů a mohla co nejlépe vycházet. Hodnota 24 byla zvolena tak, že do té doby nedokázala funkce pracovat, v tomto případě to znamená že bere nejméně 2 sousedy do každého směru. Současně důležitým nastavením této funkce je typ modelu. GWR nabízí 3 a to Continuous (Gaussian), Binary (Logistic), Count (Poisson). V této studii byl zvolený Gaussian type. V tomto typu je hodnota závislé proměnné spojitá. Použije se Gaussův model a nástroj provede běžnou regresi nejmenších čtverců. Výstupem jsou mapové výstupy, jež vyjadřují vztahy mezi závislou proměnnou a všemi nezávislými proměnnými (pro.arcgis.com, 2022). Z této funkce vychází velké množství výsledků.

Funkce Ordinary Least Squares (OLS) ze sady Spatial Statistics provádí globální lineární regresi nejmenších čtverců za účelem generování předpovědí nebo modelování závislé proměnné z hlediska jejich vztahu k sadě vysvětlujících proměnných. Primárním

výstupem pro tento nástroj je soubor zpráv. Ten se zapisuje ve spodní části podokna Geoprocessing během provádění nástroje. Nástroj OLS také vytváří výstupní třídu prvků a tabulky s informacemi o koeficientech a diagnostikou (pro.arcgis.com, 2022).

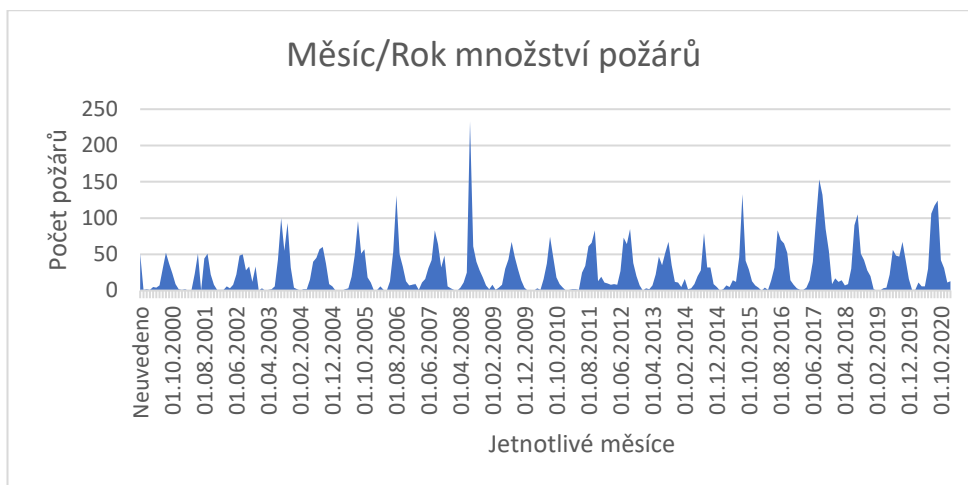
## 5 Výsledky

Na začátku studie bylo pozorováno, ve kterých měsících a letech bylo nejvíce požárů. Obrázek 2 ukazuje graf výskytu požárů v jednotlivých měsících a příloha 4 ukazuje tabulku výskytu požárů v jednotlivých měsících. Podle nich je zřejmé, že největší množství požárů se vyskytovalo v období léta. V měsících červen, červenec a srpen s celkovým množstvím 4255 ze 6784 (62,7 %) pozorovaných požárů. Na základě těchto hodnot byly požáry rozdělené na sezónní (květen až říjen) a mimo sezónní (listopad až duben). A dále se pracovalo jenom s požáry sezónními.



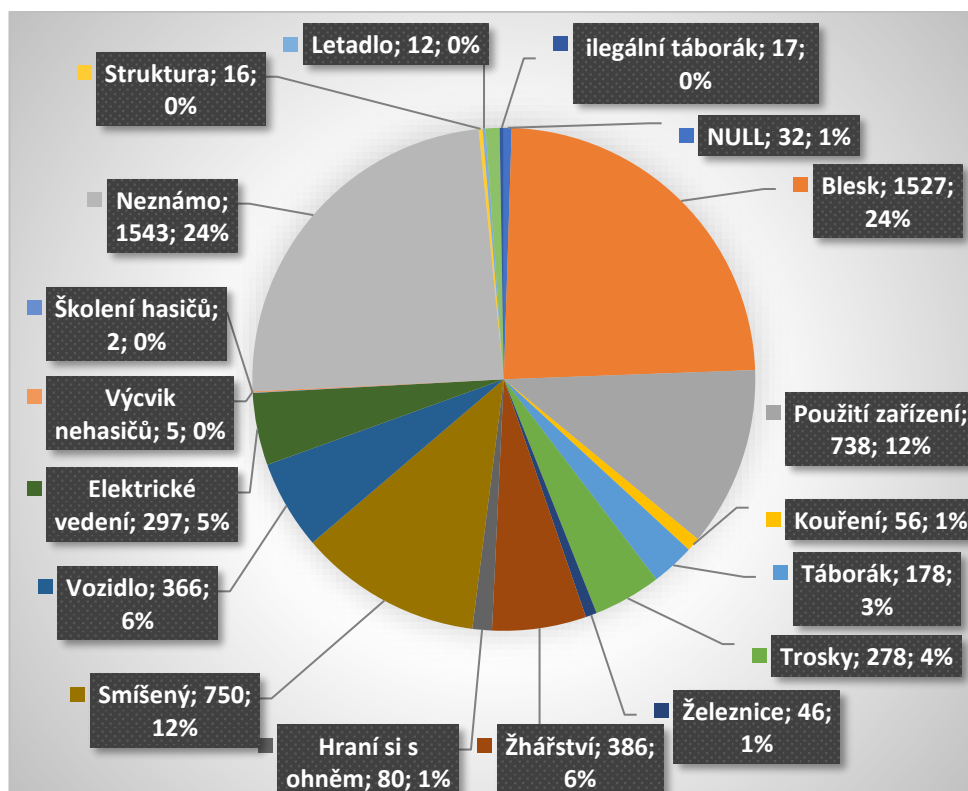
Obrázek 2: Graf požárů v jednotlivých měsících

Obrázek 3 obsahuje graf ukazující počty požárů jednotlivých měsíců v letech 2000-2020. Je vidět nárůst hodnot v letech 2003 2006, 2008, 2015, 2017 a 2020 s více než 100 požárů za měsíce v období léta.




Obrázek 3: Graf množství požárů jednotlivých měsíců v letech

Obrázek 4 a 5 ukazují koláčové grafy reprezentující příčiny vzniků požárů v letech 2000 až 2020. Obrázek 4 ukazuje podrobné informace o důvodech, za jakých pozorované požáry vznikly. Hlavními příčinami byl blesk s 1527 (24 %), použité zařízení s 738 (12 %) a neznámé příčiny s 1543 (24 %). Obrázek 5 pak ukazuje zobecněné příčiny vzniku požárů na 4 hlavní kategorie. Těmi jsou Příčiny neznámé (20 %), přírodní (19 %), lidské (52 %) a smíšené (9 %).



Obrázek 4: Koláčový graf příčin vzniků požárů



Obrázek 5: Koláčový graf ukazující obecněji příčiny vzniku požárů

Byly vytvořeny modely OLS a GWR, jejichž parametry jsou v tabulce 1 a 2. Nižší hodnoty AICc ukazují na vhodnější model v tomto případě hodnota AICc pro GWR je 4223,3257 (viz. Tabulka 2) a pro OLS je 4355,3397 (viz. Tabulka 1). Podle této hodnoty se zjistilo, že model GWR je méně ztrátový, a tudíž kvalitnější nežli model OLS. Hodnoty AICc byly odlišné pro každý způsob výpočtu, počet sousedů, a všechny vycházely méně, než byla hodnota AICc u modelu OLS. Hodnota 4223,3257 odpovídá pracování s 41 sousedními buňkami (viz. Tabulka 3). Tento počet si určil program jakožto nejrozumnější, co se týče rozložení hodnot a přesnosti.

Input Features	sezona_fish025SWPoCoWHRNinEleSlo	Dependent Variable	MEAN_POZARY
Number of Observations	746	Akaike's Information Criterion (AICc) <sup>d</sup>	4355.339676
Multiple R-Squared <sup>d</sup>	0.357526	Adjusted R-Squared <sup>d</sup>	0.345222
Joint F-Statistic <sup>e</sup>	29.056421	Prob(> F), (14,731) degrees of freedom	0.000000*
Joint Wald Statistic <sup>e</sup>	312.281212	Prob(> chi-squared), (14) degrees of freedom	0.000000*
Koenker (BP) Statistic <sup>f</sup>	134.830982	Prob(> chi-squared), (14) degrees of freedom	0.000000*
Jarque-Bera Statistic <sup>g</sup>	845.167414	Prob(> chi-squared), (2) degrees of freedom	0.000000*

Tabulka 1: Tabulka OLS diagnostik ukazující výstupy

R2	0.5912
AdjR2	0.5004
AICc	4223.3257
Sigma-Squared	14.9488
Sigma-Squared MLE	12.2346
Effective Degrees of Freedom	610.5505

Tabulka 2: Tabulka GWR diagnostik ukazující výsledky



Number of Neighbors	AICc
24	4215.3654
746	4349.2790
300	4320.0940
470	4337.1152
194	4300.6957
129	4281.2677
89	4262.8623
64	4246.4539
49	4229.5343
39	4222.1217
33	4224.0947
43	4222.6048
37	4223.5990
41	4223.3257


Tabulka 3: Tabulka ukazující hodnoty AICc pro jednotlivé počty sousedů ve funkci GWR

Tabulka 4 ukazuje tabulku OLS, která obsahuje údaje o jednotlivých proměnných a jejich hodnotách. Když je znaménko spojené s hodnotami záporné, vztah je záporný. Zatímco když je znaménko kladné, je vztah kladný. V tabulce lze pozorovat Koeficient [a] představující sílu a typ vztahu mezi každou vysvětlující proměnnou a závislou proměnnou. StdError představuje průměrnou vzdálenost, o kterou spadají pozorované hodnoty od regresní přímky. t-Statistics je odhad parametru dělený standardní chybou, ukazují na sílu vztahu mezi vstupy a závislou proměnnou. Variační inflační faktor (VIF): Vysoké VIF (> 7,5) naznačuje nadbytečnost mezi vysvětlujícími proměnnými. Z toho vyplývá, že žádná z proměnných nebyla nadbytečná. Probability určuje, pokud je hodnota označena hvězdičkou, že daná proměnná je statisticky významná ( $p < 0,05$ ). Mezi statisticky významné proměnné patří v tomto případě Listnaté stromy, smíšené stromy, jehličnaté stromy, orná půda a svažitost.

Variable	Coefficient <sup>a</sup>	StdError	t-Statistic	Probability <sup>b</sup>	Robust_SE	Robust_t	Robust_Pr <sup>b</sup>	VIF <sup>c</sup>
Intercept	-1,468127	0,638941	-2,297749	0,021842*	0,451439	-3,252108	0,001213*	-----
MEAN_KROVINY	0,084875	0,045809	1,852779	0,064318	0,032726	2,593466	0,009684*	3,845086
MEAN_LOUKY	-0,053808	0,073571	-0,731376	0,464776	0,054153	-0,993618	0,320725	1,692913
MEAN_STROMY_LISTNATE	0,503746	0,059986	8,397779	0,000000*	0,065221	7,723681	0,000000*	2,675946
MEAN_STROMY_SMISENY	0,470643	0,088408	5,323526	0,000000*	0,137320	3,427352	0,000659*	1,456286
MEAN_STROMY_JEHLICNATY	0,324092	0,055073	5,884809	0,000000*	0,051040	6,349808	0,000000*	5,051195
MEAN_VEGETACE_VYSCHLA	0,068923	0,082231	0,838164	0,402199	0,046095	1,495225	0,135302	1,494116
MEAN_VEGETACE_ZAVODNENA	0,227619	0,392416	0,580046	0,562068	0,122256	1,861828	0,063029	1,032289
MEAN_CROPLAND	0,102572	0,046121	2,223971	0,026440*	0,022577	4,543264	0,000009*	1,703638
MEAN_BARREN	-0,269101	0,143818	-1,871126	0,061727	0,095437	-2,819665	0,004941*	1,466392
MEAN_RICNI_KRAJINA	0,117880	0,177217	0,665174	0,506146	0,092876	1,269230	0,204769	1,035623
MEAN_MESTA	0,067639	0,047238	1,431863	0,152624	0,029660	2,280480	0,022851*	1,174990
MEAN_LESY_MAX	-0,092611	0,062179	-1,489424	0,136821	0,058613	-1,580035	0,114545	4,954506
MEAN_ELEVATION_MAX	-0,000034	0,000492	-0,068255	0,945586	0,000526	-0,063892	0,949059	3,607556
MEAN_SLOPE	0,322263	0,070885	4,546267	0,000008*	0,073239	4,400152	0,000016*	2,595412


Tabulka 4: Tabulka jednotlivých parametrů proměnných OLS

Obrázek 6 ukazuje rizika vzniku požárů vyjádřená z predikce GWR. Data byla rozdělena pomocí datové klasifikace Natural Breaks též známé jako Jenks. Tato metoda dělí třídy založené na přirozených seskupení obsažených v datech. Třídy jsou vytvořeny způsobem, který nejlépe seskupuje podobné hodnoty a maximalizuje rozdíly mezi třídami. V této studii byly data seskupeny do 4 tříd dle hodnot a pojmenovány „Velmi nízké riziko“, „Nízké riziko“, „Středně vysoké riziko“ a „Vysoké riziko“ to samozřejmě korelovalo s rostoucími hodnoty, jež vycházeli z predikcí GWR. Ve velmi nízkém riziku se nachází 51,20 % území, v nízkém riziku se nachází 19,71% území, ve středně vysokém riziku se nachází 17,96 % území a ve vysokém riziku vzniku požáru se pak nachází 11,13% území.



Obrázek 6: Výsledné riziko vzniku požárů z GWR

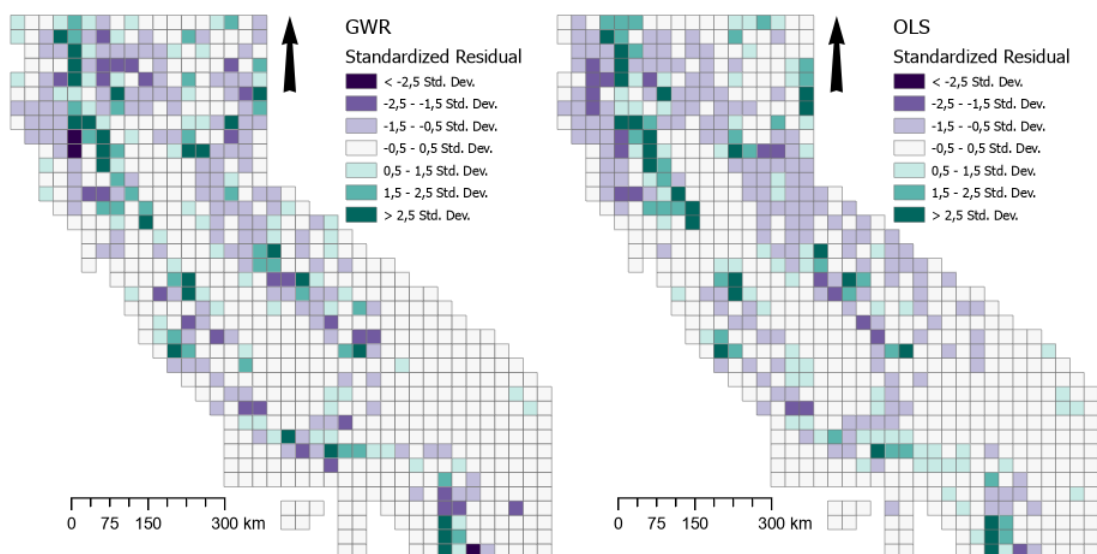
Obrázek 7 nám ukazuje místa, kde jsou hodnoty  $R^2$  přesnější (vyšší) a pro jaký model. Pokud hodnoty GWR byly vyšší, než hodnoty OLS tak jsou vyznačené zeleně a v těchto místech je výhodnější používat GWR než OLS. Hodnota Adjusted- $R^2$  u OLS je vidět v tabulce 1 a její hodnota je 0,345222. GWR dosahovalo hodnot od 0,266246 do 0,765238 a vyšší hodnotu měla na 97,3 % zájmového území.



Obrázek 7: Porovnání a zobrazení vyšší hodnoty  $R$ -squared pro GWR a OLS

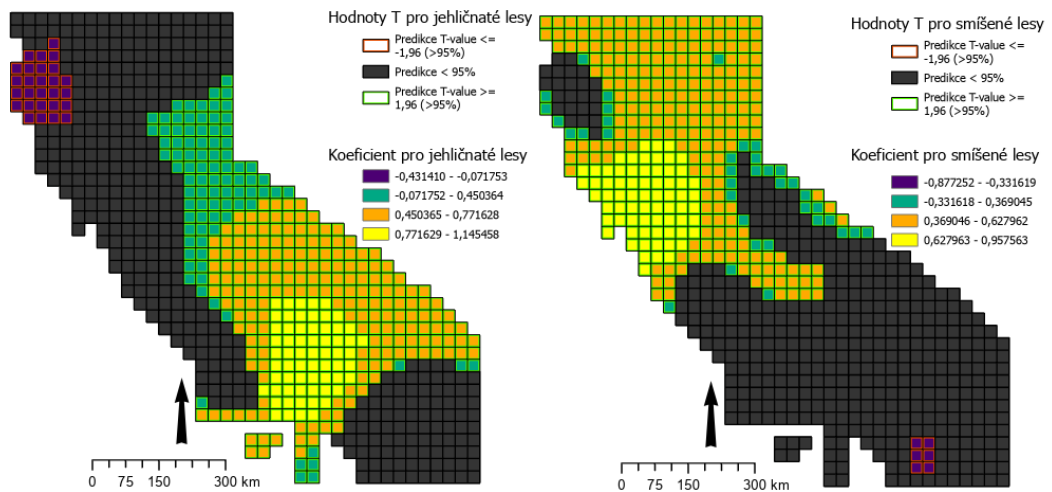
Dalším velice důležitým výsledkem bylo porovnání přesností modelu GWR a OLS (viz. Obrázek 8). Tento výsledek ukazuje, za pomoci standardních reziduí, v jakých místech zájmové oblasti se jednotlivé hodnoty lišily. V případě GWR jsou hodnoty standardních reziduí oproti OLS jasně nahodilejší a probíhá zde menší clusterizace dat (shlukování dat), oproti tomu OLS má tendenci tato data více shlukovat do větších clusterů kolem sebe. Je také možné pozorovat, že model GWR má více nejnižších a nejvyšších hodnot,

ale při pozorování celkových hodnot je GWR jednoznačně přesnější. Oproti OLS nemá takové množství pozorovaných hodnot příliš odlišných od těch očekávaných.

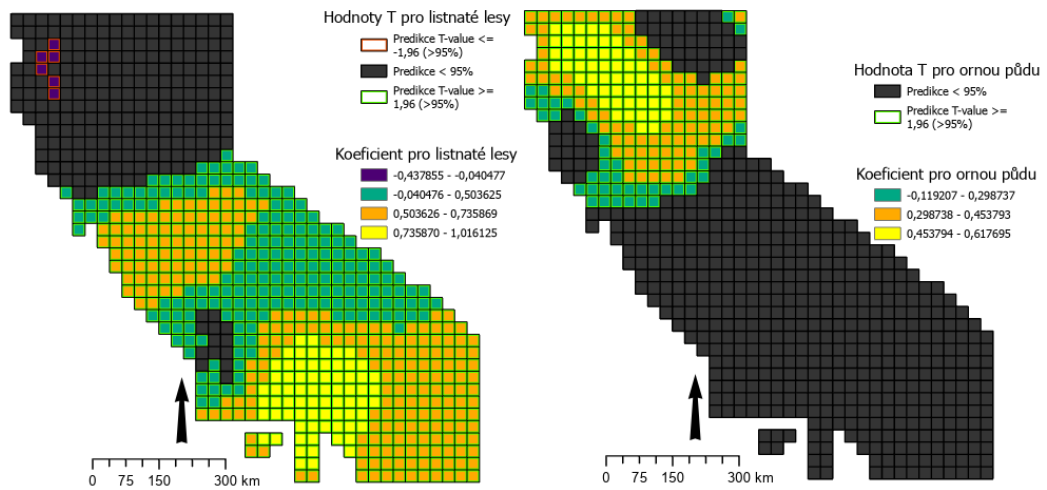


Obrázek 8: Hodnoty Standardized Residuals pro GWR a OLS

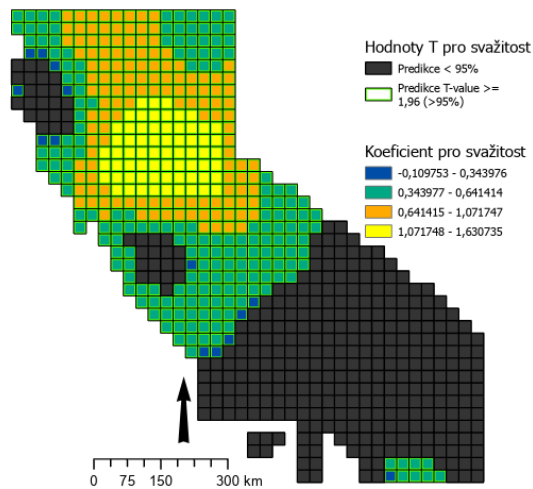
Na obrázcích 9 až 11 jsou vidět mapové výstupy obsahující dvě hlavní informace. První z nich je hodnota  $T$  označována zelenými či červenými okraji nebo černou výplní. Zelený okraj čtverců určuje, že daná veličina ovlivňuje vznik požárů v hodnotách  $T > 1,96$ . Čili čím více je tam daná veličina zastoupena tím je větší šance vzniku požáru. Oproti tomu červené okraje, ovlivňující vznik požárů v hodnotách  $< -1,96$ , znamenají, čím více je tam daná veličina zastoupena tím je menší šance, že tam požár vznikne. Černá výplň má predikci menší než 95 % (rozsah mezi hodnotami  $-1,96$  a  $1,96$ ) a tudíž pro nás nejsou tyto oblasti zajímavé. Druhou hodnotou je samotný koeficient dané veličiny. Tento koeficient úzce souvisí s hodnotnou  $T$ . Představuje sílu a typ vztahu. Čím vyšší hodnota koeficientu tím je pozorovaná větší závislost mezi požáry a pozorovanou veličinou. V případě jehličnatých lesů se dá negativní závislost vysvětlit snadněji (čím méně jich tam je, tím je menší šance vzniku požáru). Při zobecňování byly do jehličnatých lesů vztaženy i sekvojové lesy (Redwoods), které nehoří tak jednoduše jako jiné jehličnaté stromy. Sekvoje právě rostou jako dominantní strom v severozápadní části Kalifornie.



Obrázek 9: Hodnoty T a Koeficient pro jehličnaté a smíšené lesy



Obrázek 10: Hodnoty T a Koeficient pro listnaté lesy a ornou půdu



Obrázek 11: Hodnota T a Koeficient pro svažitost

## 6 Diskuze

Je důležité říct, že tato práce je velice zobecněná a zjednodušená pro potřeby bakalářské práce. Není doporučeno tuto práci používat jako práci, která by se dala použít v případě modelování příčin požárů v Kalifornii.

V původní myšlence této práce bylo i pracování s mimo sezónními požáry, ale kvůli jejich množství a rozložení s nimi nebylo možné pracovat, GWR je nedokázala přijmout a počítat s nimi.

Jelikož funkce GWR nedokázala brát velké množství nulových hodnot bylo nutné zobecnit velké množství dat a ztrácela se přesnost. Samotná vrstva WHR byla z původních 58 prvků zobecněná na 11, tak se ztratila informace o tom, které přesné stanoviště ovlivňovalo GWR nejvíce. Z práce vyplývá, že to byly jehličnaté, smíšené, listnaté lesy, orná půda a svažitost ale ty obsahovali dohromady 26 z původních 58 prvků. Jehličnaté lesy jich obsahovali 12, listnaté lesy 11 a zbytek po 1 prvku. Proto nevíme, který přesně typ stanoviště z jehličnatých a smíšených lesů to ovlivňoval nejvíce a mohlo se stát, že to byl třeba jenom 1 a ostatní je neovlivňovaly. Ale to, že lesy významně ovlivňují vznik požárů dokazuje i práce od autorů Doerr a Santín z roku 2016, kteří zjistili, že existují důkazy o nedávném zvýšení proporcionální závažnosti požáru pro konkrétní typy lesů v Kalifornii, ale nezávislé studie nepodporují představu o celkovém zvýšení závažnosti požáru za posledních několik desetiletí v lesnaté krajině přizpůsobené požárům na západě USA (Doerr & Santín, 2016).

Výsledek byl silně ovlivněn velikostí Fishnetu, ten nedokázal kvůli nulovým hodnotám projít funkcí GWR, a to i po zobecnění WHR. Proto proběhlo zvětšování velikosti fishnetu a při převodu z původních 24,01 km<sup>2</sup> na finálních 597,66 km<sup>2</sup> proběhla velká ztráta detailních informací. Zejména za to mohlo průměrování původních menších obdélníků. Při finální podobě každý obdélník obsahoval přibližně 25 původních (menších) obdélníků.

Interpretace výsledků je také ovlivněna závěrečnou klasifikací predikce do čtyř kategorií. Zvolena byla metoda Jenks, která zohledňuje rozložení četnosti hodnot v datech. Jiná klasifikační metoda by mohla zejména o výskytu nejrizikovějších kategoriích vyvolat lehce odlišný dojem.

Práce se omezila pouze na faktory, které jsou (nebo lze považovat za) v čase neměnné. Tyto faktory nejsou ani zdaleka nejdůležitějšími při modelování skutečných požárů, ale

stále jsou součástí. V realitě se kromě typu paliva (WHR), svažitosti (oproti této práci se řeší i směr) a nadmořské výšky, řeší především vítr (směr a síla), teplota, vlhkost (přítomnost vody v atmosféře), déšť (voda v zemi) a atmosférický tlak.

## 7 Závěr

Předložená bakalářská práce se zabývá modelováním rizika vzniku lesních požárů v Kalifornii za pomoci geografické vážené regrese v letech 2000 až 2020. Hlavně zkoumá procesy a příčiny vzniků požárů, jaké faktory je ovlivňují a jestli je vhodné použití GWR namísto klasické lineární regrese.

V teoretické části se práce zabývá problematikou požárů a jejími vlivy na krajinu. Představuje požár nejenom jako přírodní katastrofu ale i jako důležitou součást přírody. Vysvětluje negativní i pozitivní účinky požáru na krajinu a jakou roli hraje člověk v ovlivňování přírody a jejího požárního režimu. Řeší metody používané k modelování požárů nejenom v Kalifornii ale i jinde ve světě. Na konci řeší hlavní parametry, jež mohou ovlivňovat vznik požárů a přírodní či člověkem způsobené požáry.

V praktické části se práce zabývá několika otázkami a cíli. Prvním a také hlavním cílem práce bylo porozumět GWR a dokázat vyjádřit výsledky jež z ní vychází. Z GWR vychází, na rozdíl od klasické regrese, velké množství map popisující vlivy jednotlivých vstupních parametrů, ale stejně jako u regrese také hodnoty T, standardní reziduály, hodnoty  $R^2$  a hodnoty AICc. Hlavním výsledkem je mapový výstup, který určuje pravděpodobnost vzniku požáru. Podle tohoto modelu se ve velmi nízkém riziku nachází 51,20 % území, v nízkém riziku se nachází 19,71% území, ve středně vysokém riziku se nachází 17,96 % území a ve vysokém riziku vzniku požáru se pak nachází 11,13% území.

Dalšími dílčími cíli pak bylo porovnání GWR, a právě zmíněné klasické regrese OLS. Právě pomocí hodnot  $R^2$  a standardních reziduálů bylo určeno, že GWR je pro modelování požárů výhodnější, protože bere v potaz prostorové vztahy mezi proměnnými a zároveň je přesnější na základě hodnoty AICc. Hodnoty  $R^2$  byly vyšší u GWR na 97,3 % zkoumaného území, a tak bylo výhodnější na těchto místech použít metodu GWR. Porovnáním StdRes bylo u GWR sledováno menší shlukování dat (menší clusterizace), na rozdíl od OLS, která má tendenci u sebe držet hodnoty ve shlucích (clusterecech) a tak byla metoda GWR výhodnější.



## 8 Seznam použitých zdrojů

Alexander M. E., 2000: Fire behaviour as a factor in forest and rural fire suppression, Forest Research Bulletin No. 197, Forest and Rural Fire Scientific and Technical Series, Report No. 5

Andrews P. L. 2012: Modeling wind adjustment factor and midflame wind speed for Rothermel's surface fire spread model. Gen. Tech. Rep. RMRS-GTR-266. Fort Collins, CO: U.S. Department of Agriculture, Forest Service, Rocky Mountain Research Station. 39 p.

Arroyo L. A., Pascual C., Manzanera J. A., 2008 Fire models and methods to map fuel types: The role of remote sensing, Forest Ecology and Management, Volume 256, Issue 6,

Balch J. K., Bradley B. A., Abatzoglou J. T., Nagy R. C., Fusco E. J., Mahood A. L., 2017: Human-started wildfires expand the fire niche across the United States. Proc Natl Acad Sci 114(11): 2946–2951

Bond W. J., Midgley G. F., Woodward F. I., 2003: The importance of low atmospheric CO<sub>2</sub> and fire in promoting the spread of grasslands and savannas. Global Change Biology, 9: 973-982.

Brillinger D. R., Preisler H. K., Benoit, J. W. 2006: Probabilistic risk assessment for wildfires. Environmetrics: The official journal of the International Environmetrics Society, 17(6), 623-633.

Cary G. J., Keane R. E., Gardner R.H., Lavorel S., Flannigan I.D., Davies C. L., Lenihan J. M., Rupp T. S., Mouillot F., 2006: Comparison of the sensitivity of landscape-fire-succession models to variation in terrain, fuel pattern, climate and weather Landscape, Ecol., 21, pp. 121-137

Census.gov, [online], [cit. 2021.12.06]. Dostupné z <  
<https://www.census.gov/quickfacts/CA> >

Deeming J.E., Burgan, R.E., Cohen, J.D., 1977: The National Fire Danger Rating System. Rep. No. GTR INT-39. USDA Forest Service, Intermountain Forest and Range Experiment Station, Ogden, UT.

Dombeck M. P., Williams J. E., Wood C. A., 2004: Wildfire policy and public lands: integrating scientific understanding with social concerns across landscapes, *Conservation Biology* 18: 883–889.

Duff T. J., Keane, R. E., Penman, T. D., Tolhurst, K. G., 2017: Revisiting wildland fire fuel quantification methods: the challenge of understanding a dynamic, biotic entity. *Forests* 8, 351

Fidelis A., Blanco C., Müller S., Pillar V.D., Pfadenhauer J., 2012: Short-term changes caused by fire and mowing in Brazilian Campos grasslands with different long-term fire histories, *J. Veg. Sci.*, 23, pp. 552-562

Fidelis A., Alvarado S., Barradas A., V. Pivello V., 2018: The year 2017: megafires and management in the cerrado, *Fire*, 1, p. 49

Fidelis A., 2020: Is fire always the “bad guy”? *Flora*, Volume 268, 151611, ISSN 0367-2530

Finney M. A., 2021: The wildland fire system and challenges for engineering, *Fire Safety Journal*, Volume 120, 103085, ISSN 0379-7112,

Fire.ca.gov [online], [cit. 2022.03.12]. Dostupné z  
<<https://www.fire.ca.gov/media/px5lnaaw/suppressioncostsonepage1.pdf>>

Flannigan M. D., Wotton B. M., 1991: Lightning-ignited forest fires in northwestern Ontario. *Can. J. For. Res.* 21, 277–287

Flannigan M. D., Cantin A. S., de Groot W. J., Wotton M., Newbery A., Gowmann L. M., 2013: Global wildland fire season severity in the 21st century, *Forest Ecology and Management*, Volume 294, Pages 54-61, ISSN 0378-1127

Fotheringham A. S., Brunson C., Charlton M. E., 2009: Geographically weighted regression. *The Sage handbook of spatial analysis*, 1, 243-254.

Ganteaume A, Jappiot M., 2013: What causes large fires in Southern France. *For Ecol Manag* 294:76–85

Gill A. M., Stephens S. L., Cary G. J., 2013: The worldwide “wildfire” problem, *Ecol. Appl.*, 23, pp. 438-454

Glaser J., 2003: *California: Land of Liberty*, Capstone Press, 64 s. 9-

Glasspool I. J., Edwards E., Axe L., 2004: Charcoal in the Silurian as evidence for the earliest wildfire. *Geology*, 32 (5): 381–383

Goldammer J. G., 2021: Forests on Fire, *Science*, 284, 5421, 1782-1783

Hantson S., Pueyo S., Chuvieco E., 2015: Global fire size distribution is driven by human impact and climate. *Glob. Ecol. Biogeogr.*, 24, 77–86.

Hawbaker T. J., Radeloff V. C., Stewart S. I., Hammer R. B., Keuler N. S., Clayton M. K., 2013: Human and biophysical influences on fire occurrence in the United States, *Ecological*, Volume 23, Issue 3, 565-582

Hesseln H., 2018: Wildland Fire Prevention: a Review. *Curr Forestry Rep* 4, 178–190

Charlton, M., Fotheringham, S., & Brunson, C., 2009: Geographically weighted regression. White paper. National Centre for Geocomputation. National University of Ireland Maynooth, 2.

Chuvieco E., Cocero, D., Riano, D., Martín, P., Martínez-Vega J., Riva J.d.l., Pérez, F., 2004: Combining NDVI and surface temperature for the estimation of live fuel moisture content in forest fire danger rating. *Remote Sensing of Environment* 92, 322–331

Kanga S., Sharma L. K., Pandey P. C., Nathawat M. S., Sharma S. K., 2013: Forest fire modeling to evaluate potential hazard to tourism sites using geospatial approach. *Journal of Geomatics*, 7(1), 93-99.

Keeley J. E., Pausas J. G., Rundel P. W., Bond W. J., Bradstock R. A., 2011: Fire as an evolutionary pressure shaping plant traits, *Trends in Plant Science*, Volume 16, Issue 8, Pages 406-411, ISSN 1360-1385

Keeley, J. E., et Syphard, A. D., 2019: Twenty-first century California, USA, wildfires: fuel-dominated vs. wind-dominated fires. *Fire Ecology*, 15(1), 1-15.

Koutsias N., Martínez J., Chuvieco E., Allgöwer B., 2005: Modelling Wildland Fire Occurrence in Southern Europe by Geographically Weighted Regression Approach. In: 5th International Workshop on Remote Sensing and GIS Applications to Forest Fire Management: Fire Effects Assessment (pp.57-60)

Lundgren S., Mitchell, W., Wallace, M., 1995: A status report on NFMAS—an interagency system update project. *Fire Management Notes* 55, 11–12.

Martell D. L., Otukol S., Stocks B. J., 1987: A logistic model for predicting daily people-caused forest fire occurrence in Ontario. *Canadian Journal of Forest Research* 17, 394–401.

Martínez J., Vega-García C., Chuvieco E., 2009: Human-caused wildfire risk rating for prevention planning in Spain, *Journal of Environmental Management*, Volume 90, Issue 2, Pages 1241-1252,

Melo R. T., 2020: We Didn't Start the Fire...Did We? Analyzing Why California Cannot Seem to Extinguish Its Worsening Wildfire Problem, *Villanova Environmental Law Journal*, Volume 31, Issue 1, Article 5, p. 3

Mott J. A., Meyer P., Mannino D., Redd S. C., Smith E. M., Gotway-Crawford C., Chase E., 2002: Wildland forest fire smoke: health effects and intervention evaluation, *The Western journal of medicine*, 176(3), 157–162.

Nagy R., Fusco E., Bradley B., Abatzoglou J. T., Balch J., 2018: Human-related ignitions increase the number of large wildfires across U.S., Ecoregions. *Fire*, 1, 4

National Interagency Fire Center, [online], [cit. 2022.03.06]. Dostupné z <<https://www.nifc.gov/fire-information/statistics/suppression-costs>>

Pausas J.G. et Vallejo, V.R., 1999: The role of fire in European Mediterranean ecosystems. In: Chuvieco, E. (Ed.), *Remote Sensing of Large Wildfires*. Springer, Berlin, p. 3–16

Podur J., Martell, D. L., Csillag, F., 2003. Spatial patterns of lightning-caused forest fires in Ontario, 1976–1998. *Ecol. Model.* 164, 1–20

pro.arcgis.com [online], [cit. 2022.03.12]. Dostupné z <<https://pro.arcgis.com/en/pro-app/latest/tool-reference/spatial-statistics/how-ols-regression-works.htm>>

Rothermel, P. et Richard C., 1972: A mathematical model for predicting fire spread in wild land fires. USDA Forest Service Research Paper INT - 115, Ogden, Utah, USA

Schlosser J. S., Braun R.A., Bradley T., Dadashazar H., MacDonald A. B., Aldahif A. A., Aghdam M. A., Mardi A. H., Xian P., Sorooshian A., 2017: Analysis of aerosol composition data for western United States wildfires between 2005 and 2015: dust emissions, chloride depletion, and most enhanced aerosol constituents. *J. Geophys. Res. Atmos.*, 122, pp. 8951-8966

Schoenherr A. A., 2017: A Natural History of California, Second Edition, University of California Press. 632 s.

Stephens, S.L., et B.M. Collins 2004: Fire regimes of mixed conifer forests in the northcentral Sierra Nevada at multiple spatial scales. *Northwest Science* 78: 12–23.

Stephens, S. L., Adams, M. A., Handmer, J., Kearns, F. R., Leicester, B., Leonard, J., & Moritz, M. A., 2009: Urban–wildland fires: how California and other regions of the US can learn from Australia. *Environmental Research Letters*, 4(1), 014010.

Su, X., Yan X., Tsai C. L., 2012: Linear regression. *Wiley Interdisciplinary Reviews: Computational Statistics*, 4(3), 275-294.

Syphard, A. D., Radeloff V. C., Keeley J. E., Hawbaker T. J., Clayton M. K., Stewart S. I., Hammer R. B., 2007: Human influence on California fire regimes. *Ecological Applications* 17: 1388–1402.

Theobald D. M. et Romme W. H., 2007: Expansion of the US wildland–urban interface *Landsc. Urban Plan.* 88, 340–54

Thomas D., Butry D., Gilbert S., Webb D., Fung, J., 2017: The Costs and Losses of Wildfires: A Literature Review. NIST Special Publication 1215,

Wagner C. E. v., et Forest P., 1987: "Development and structure of the canadian forest fireweather index system." *Can. For. Serv., Forestry Tech. Rep.*

Wang D., Guan D., Zhu S., Kinnon M. M., Geng G., Zhang O., Zheng H., Lei T., Shao S., Gong P., Davis S. J., 2020: Economic footprint of California wildfires in 2018. *Nat Sustain* 4, 252–260

Weise D. R. et Biging G. S., 1997: A Qualitative Comparison of Fire Spread Models Incorporating Wind and Slope Effects, *Forest Science*, Volume 43, Issue 2, p. 170–180,

Welsh H. H. jr., 1994: Bioregions: An ecological and evolutionary perspective and a proposal for California. *Fish and Game* (80)3: 97 - 124

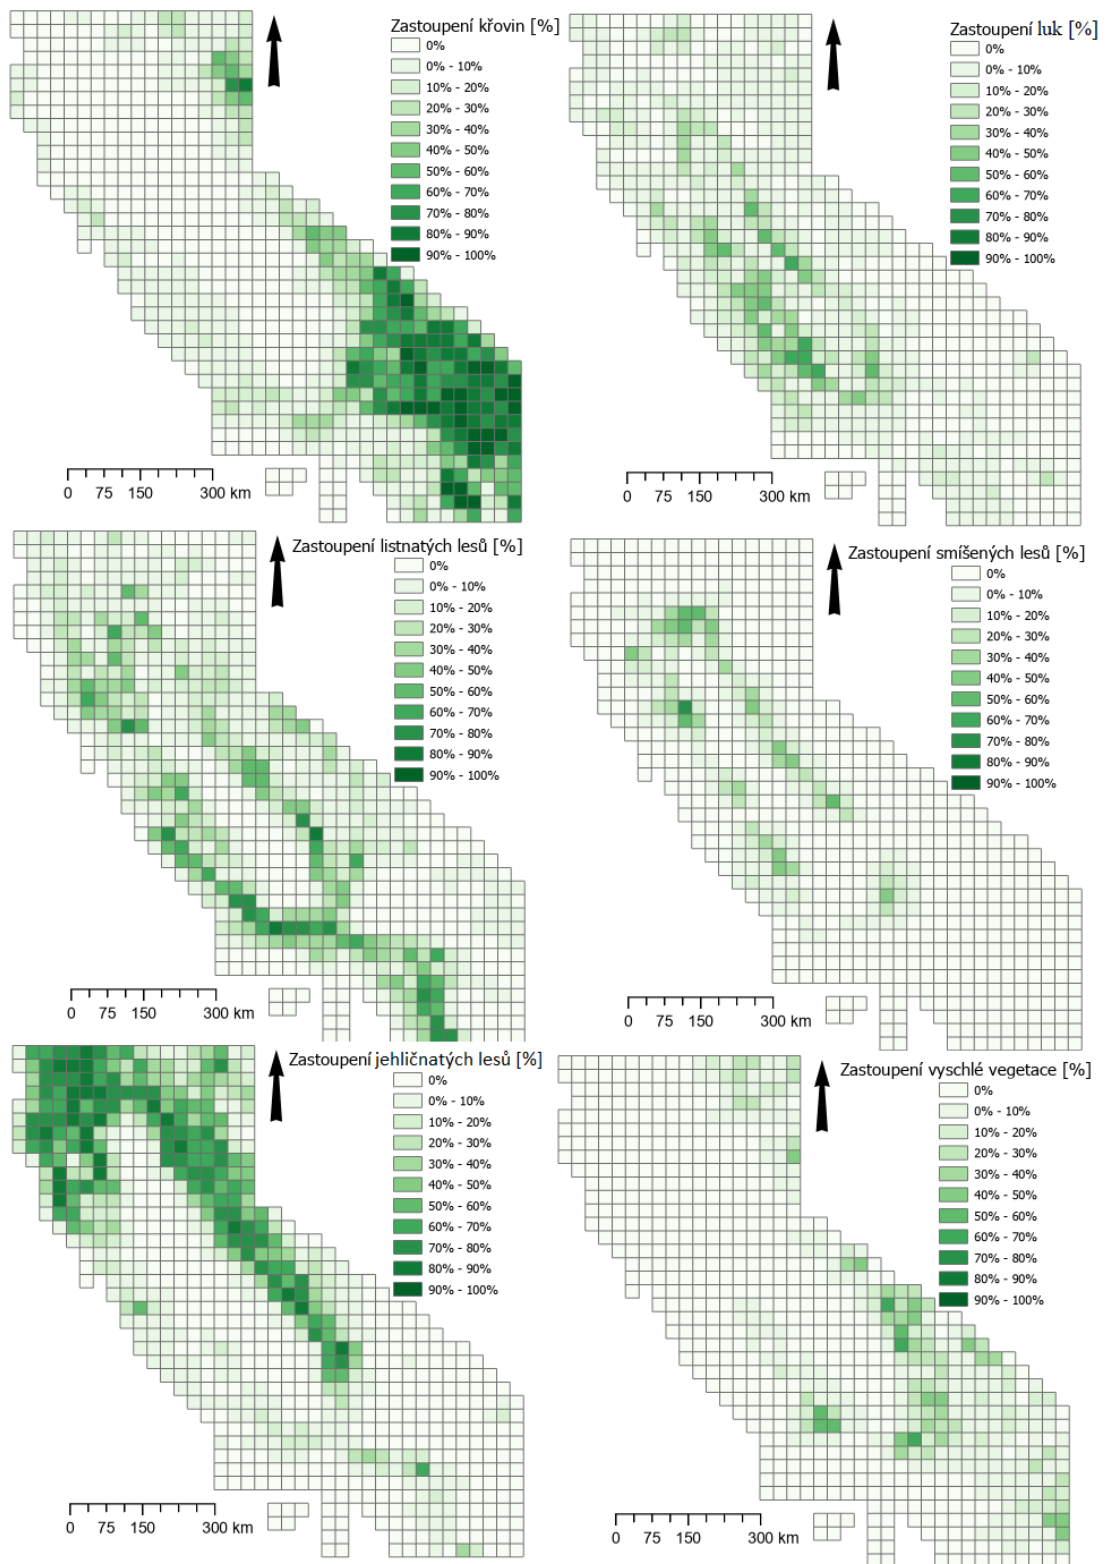
Yan, X. et Su, X. (2009). *Linear regression analysis: theory and computing*. World Scientific. P. 9

## 9 Přílohy

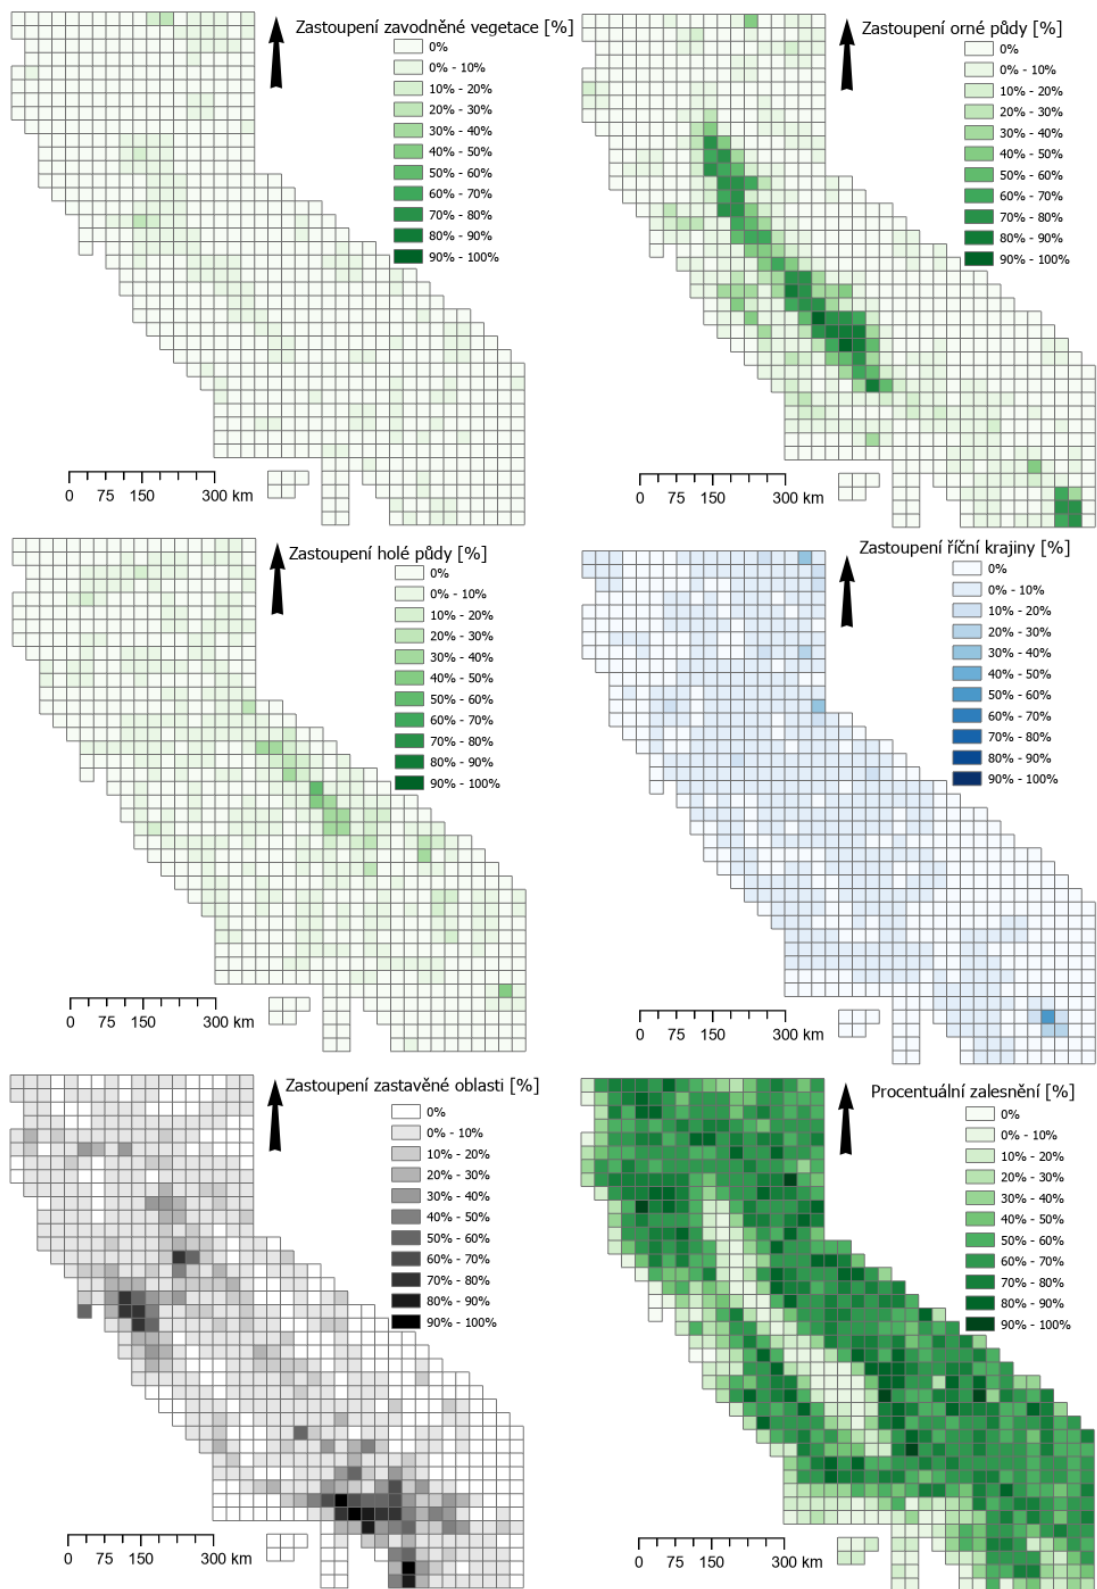
Rok	Spálená plocha (a)	Oběti	Zničeno budov
2013	601 635	1	456
2014	625 540	2	471
2015	880 899	7	3 159
2016	669 534	6	1 274
2017	1 548 429	47	10 280
2018	1 975 086	100	24 226
2019	259 823	3	732
2020	4 304 379	33	11 116
Průměr	1 358 166	25	6 464

*Příloha 1: Tabulka spálené plochy, obětí a zbořených budov v letech 2013 až 2020*





*Příloha 2: Vstupní vrstvy křovin, luk, listnatých lesů, smíšených lesů, jehličnatých lesů a vyschlé vegetace*



Příloha 3: Vstupní vrstvy zavodněné vegetace, orné půdy, holé půdy, říční krajiny, zastavěné oblasti a procentuálního zalesnění

<i>Měsíce</i>	<i>Četnost</i>
Leden	78
Únor	67
Březen	80
Duben	157
Květen	503
Červen	1297
Červenec	1685
Srpen	1273
Září	932
Říjen	439
Listopad	187
Prosinec	86

*Příloha 4: Tabulka výskytů požárů v jednotlivých letech*