

MASARYKOVA UNIVERZITA
FILOZOFICKÁ FAKULTA
ÚSTAV ARCHEOLOGIE A MUZEOLOGIE

Tomáš Tencer

**TVORBA PREDIKTÍVNEHO MODELU V OBLASTI
SEVEROZÁPADNÉHO SLOVENSKA V KONTEXTE
VČASNÉHO STREDOVEKU**

(magisterská diplomová práca)

Vedúci práce: Mgr. Petr Dresler, Ph.D.

BRNO

2011

Čestné prehlásenie:

Prehlasujem, že som predloženú diplomovú prácu vypracoval samostatne s využitím uvedenej literatúry.

V Brne dňa: 22.5.2011

Pod'akovanie:

Chcel by som poďakovať všetkým pedagógom a konzultantom, ktorý svojimi podnetmi a vecnými radami prispeli k dokončeniu tejto diplomovej práce. Predovšetkým sa chcem poďakovať vedúcemu mojej diplomovej práce Mgr. Petrovi Dreslerovi , PhD. za čas, ktorý mi venoval pri zodpovedaní mojich otázok a za odborné vedenie. Rovnakou mierou by som chcel poďakovať profesorovi Jiřímu Macháčkovi, PhD za cenné rady, pripomienky a impulzy pri písaní práce.

Veľké poďakovanie patri aj moje rodine a známym, za všemožnú podporu a trpezlivosť.

Obsah

Obsah.....	1
Úvod	3
Geografické vymedzenie územia	4
Topografia vybranej oblasti	5
Morfograficko-morfometrická typizácia regiónu	6
Geologická stavba vybranej oblasti.....	8
Pedológia skúmaného regiónu	10
Hydrológia	12
Rieka Váh.....	13
Rieka Kysuca	13
Rieka Nitra	13
Rieka Turiec.....	14
Prírodné podmienky v skúmanej oblasti	15
Podnebie	15
Vegetácia	15
Účel prediktívneho modelovania	18
Metodika	19
Postup pri vytváraní modelu	19
Fáza 1 – tvorba primárnych vrstiev.....	21
Archeologické informačné zdroje.....	23
Geografické informačné zdroje.....	23
Vojenská topografická mapa	23
Výškopisný model územia (DEM)	24
Geologická mapa (GEO)	25
Mapa potenciálnej prirodzenej vegetácie (FLORA).....	25
Mapa pôdných typov (SOIL).....	27
Fáza 2 - tvorba sekundárnych vrstiev a ich testovanie	27
Vrstva archeologických komponentov	27
Vrstvy geografických premenných	32
LR150.....	33
ASPECT.....	35
SLOPE.....	41
TCI.....	42
TPI	45
Vrstvy časových vzdialeností	48
TNIVA.....	49

THRADISKA	50
Vrstvy enviromentálných premenných	53
FLORA a SOIL	53
Štatistické analýzy a výpočty.....	53
Testy signifikancie	53
Chí-kvadrát	54
Testy normality	54
Jednovzorkový t-test.....	56
Wilcoxonov znamienkový test.....	57
Mann-Whitneyho test	58
Pridelovanie váh v rámci premenných.....	58
Pridelenie váh jednotlivým premenným.....	60
Analýza.....	63
Tvorba DESIGN a TEST SAMPLE	64
Testy signifikancie.....	67
Vrstvy premenných v kategorickom (nominálnom) formáte.....	67
Vrstvy so spojitými (ordinálnymi) premennými.....	69
Pridelenie váh v rámci premenných.....	76
Vrstvy nominálnych premenných.....	76
Vrstvy ordinárnych premenných.....	78
SLOPE.....	78
LR150.....	80
TCI.....	82
TNIVA.....	84
THRADISKA	85
Pridelenie váh jednotlivým premenným a výpočet modelu	88
Určenie hraníc medzi zónami rozdielneho potenciálu a optimalizácia modelov	88
Testovanie výkonu modelov.....	94
Otázka vplyvu odlišných váh	94
Otázka vplyvu blízkosti centrálnych miest.....	97
Porovnanie optimalizovaných modelov	111
Výsledky	116
Diskusia a kritika	120
Záver	122
Prílohy	125
Zoznam tabuliek, grafou a vyubrazení v texu	136
Literatúra	140


Úvod

Riešenie stále komplexnejších otázok a používanie rozsiahlych súborov dát vyžaduje aplikáciu geografických informačných systémov (GIS) a štatistických metód, ktoré sa stavajú nevyhnutnou podmienkou pre efektívne prediktívne modelovanie (KUNA 1996, 597). Cieľom predkladanej práce je otestovanie metód a postupov prediktívneho modelovania a vytvorenie prediktívneho modelu včasno stredovekého osídlenia v regióne severozápadného Slovenska. Takto vzniknutý model môže tvoriť prvý stupeň v iteratívnom procese skúmania daného regiónu, prostredníctvom ktorého je možno definovať základné faktory ovplyvňujúce osídlenie študovanej oblasti. Práca z časti nadväzuje na diplomovú prácu Petra Mila (MILO 2000) o štruktúre stredovekého osídlenia v hornatých oblastiach Slovenska. Z katalógu priloženého k tejto práci pochádza väčšina záznamov o archeologických komponentoch použitých pri tvorbe modelov. Veľkou inšpiráciou pre výber témy my boli práce profesora J. Macháčka (MACHÁČEK 2001) a dr. P. Dreslera (DRESLER - MACHÁČEK 2008) a dr. J. Goláňa (GOLÁŇ 2001). V snahe o elimináciu chyby vznikajúcej pri kategorizácii premenných som tvorbu modelu založil na premenných v spojitom formáte. Použitie týchto premenných bolo podmienené ich štatisticky dokázaným vplyvom na štruktúru osídlenia. Práve identifikácia vplyvu a nastavenie jeho miery tohto vplyvu na osídlenie, boli jedným z cieľov práce. V záverečnej fáze práce som sa rozhodol otestovať teóriu o vplyve centrálnych areálov na štruktúru osídlenia v regióne severozápadného Slovenska.

Prácu som písal v slovenskom jazyku. Vzhľadom k použitiu programov bez slovenskej lokalizácie som niektoré termíny ponechal v pôvodnom (anglickom) znení. V týchto prípadoch preklady termínov uvádzam buď v texte alebo v popiske tabuľky.

Geografické vymedzenie územia


Sledované územie sa nachádza na severozápade Slovenska (Obr. 1). Hranice oblasti sú na západe tvorené slovenskými hranicami s Českou republikou a na severe s Poľskou republikou. Južná hranica je vzdialená 15 km od hranice okresov Ilava a Prievidza. Východná hranica sa potom tiahne 15 km na východ, popri hraniciach okresov Čadca, Žilina, Martin a Turčianske Teplice. Rozloha skúmanej oblasti je približne 8600 km². Cieľom bolo spracovať komponenty patriace do okresov Bytča, Čadca, Ilava, Kysucké Nové Mesto, Martin, Považská Bystrica, Prievidza, Púchov, Turčianske Teplice a Žilina. Striktné vymedzenie hraníc by však mohlo z analýz vylúčiť komponenty navzájom súvisiace v prípade ak by ležali v administratívnom celku ktorý nebol do štúdie zahrnutý. Hranicu posunutú 15 km od okraja dnešných okresom som považoval za dostatočnú na udržanie kompaktnosti sídelných štruktúr a eliminovania chyby v analýzach, vzniknuté absenciou vplyvu faktorov nachádzajúcich sa mimo región (DANIELISOVÁ 2008).



Obr. 1 – Vymedzenie skúmanej oblasti v rámci územia Slovenska.

Topografia vybranej oblasti

Oblasť zaradenú do štúdie zo severnej strany uzaviera pásмо Vonkajších Západných Karpát. Najsevernejšou časťou tohto pásu je územie z časti sem zasahujúcich Západných Beskydy a to celkami Moravsko-sliezskych Beskýd a Jablunkovského medzihoria. Južnejšie potom Turzovská vrchovina ktorá prechádza do oblasti Slovensko-moravských Karpát, pohoria Javorníkov na západnej hranici oblasti. Na juhozápadnej hrane potom z časti zasahuje geomorfologický celok Bielych Karpát, na ktorý v inundácii rieky Váh nadväzuje celok Považského podolia. Centrálnej časti územia potom dominujú celky patriace do Fatransko-tatranskej oblasti, menovite: Strážovské vrchy, Súľovské vrchy, Malá Fatra a oblasti dvoch kotlín Žilinskej a Turčianskej kotliny. Na tento celok v severovýchodnom smere nadväzuje oblasť Stredných Beskýd oblasťou zvanou Kysucká vrchovina. Západnú hranicu vymedzeného regiónu tvorí geomorfologický celok Veľkej Fatry (Obr. 2);(HRNČÁROVÁ 2002).



Obr. 2 – Dislokácia geomorfologických útvarov na sledovanom území.

Morfograficko-morfometrická typizácia regiónu

Nadmorská výška a reliéf krajiny sú veľmi dôležitými činiteľmi, ktoré vo veľkej miere ovplyvňujú priestorové rozmiestenie fyzicko-geografických zložiek a ich prvkov – teplôt, zrážok, pôdy, flóry a fauny, ale aj spôsob využívania samotnej krajiny. V rámci reliéfu krajiny možno sledovať územia, ktoré oproti svojmu okoliu vykazujú istú vnútornú homogenitu. Môžeme hovoriť o svahoch, plošinách, kužeľoch či panvách. Častejšie sa identifikujú väčšie geomorfologické časti ako rovina, pahorkatina, vrchovina, hornatina a veľhornatina. Na základe miery (hlavne vertikálnej) členitosti boli obsahovo spresnené morfografické typy georeliéfu (VAŠKOVÝCH 1977, 21).

Na sledovanom území som za použitia nástrojov priestorových analýz v prostredí programu ArcGIS (Modul Spatial Analyst) zistil percentuálne zastúpenie morfografických typov. Vertikálna členitosť bola určená na základe relatívnych výškových rozdielov na plochách kruhov s polomerom 2 km (LUKNIŠ - MAZÚR 1986, 54).

Morfografický typ georeliéfu	Vertikálna členitosť [m]	km ²	%
rovina	0 – 30	11	0.13
pahorkatina	31 – 100	412	4.79
nižšia vrchovina	101 – 180	595	6.91
vyššia vrchovina	181 – 310	1505	17.49
nižšia hornatina	311 – 470	3020	35.11
vyššia hornatina	471 – 640	1978	22.99
veľhornatina	nad 641	1081	12.57

Tab. 1 - Morfologické typy georeliéfu na sledovanom území.

Ako je vidieť z predchádzajúcej tabuľky (Tab. 1), z morfografických typov georeliéfu sú najväčšou mierou zastúpené nižšie hornatiny, vyššie hornatiny a vyššie vrchoviny. Do kategórie rovín je možno zaradiť len malú oblasť o veľkosti necelých 11 km² v okrese Ilava. Rovina, s lokálnym prevýšením maximálne 30 m sa nachádza v blízkosti toku rieky Váh v pomerne husto osídlenom území medzi mestami Ilava a Dubnica nad Váhom. Oblasť pahorkatiny s prevýšeniami od 31 do 100 m zaberá 412 km². Tento typ charakterizuje obe hlavné kotliny v regióne: Turčiansku a Žilinskú. Taktiež časť sem zasahujúcej Hornonitrianskej kotliny s riekou Nitra a údolie Váhu zhruba po hranicu Lednické Rovné – Beluša. Oblasť pahorkatiny prechádza prostredníctvom nižšej vrchoviny do oblasti vyššej vrchoviny. Táto kategória je najnižším stupňom počínajúcich pohorí.

Patria sem okraje horských kotlín a oblasť Považského Podolia, spolu s územiami s okoliach miest Púchov, Považská Bystrica, Bytča a čiastočne aj Kysucké Nové Mesto.

Prvotný predpoklad o nerovnomernom rozložení archeologických komponentov môžeme pozorovať aj prostredníctvom chi-kvadrát testu (Tab. 2). Aj napriek očakávanému výsledku je tento poznatok dôležitý. Pri tvorbe modelu totiž, počítame s takýmto nepravidelným rozdelením lokalít. Predpoklad o takomto nepravidelnom rozložení bol potvrdený na hladine významnosti 0,05.

	Kategória	Plocha %	Observed	Expected	O-E	chiQuadrat
0 – 30	rovina	0.13	0	0.12	-0.12	0.11637
31 – 100	pahorkatina	4.79	8	4.36	3.64	3.04240
101 – 180	nižšia vrchovina	6.92	18	6.29	11.71	21.76825
181 – 310	vyššia vrchovina	17.50	32	15.92	16.08	16.23766
311 – 470	nižšia hornatina	35.11	20	31.95	-11.95	4.46858
471 – 640	vyššia hornatina	22.99	13	20.93	-7.93	3.00155
nad 641	veľhornatina	12.57	0.00	11.44	-11.44	11.43583
		100	91.00	91		60.07064
Chi-Square = 60.07064 df = 6 p = .000000						

Tab. 2 – Test Chi-kvadrát zastúpenia archeologických komponentov v geomorfologických kategóriách.

Geologická stavba vybranej oblasti

Vybrané územie možno na základe morfológických a geologických podmienok rozdeliť do troch hlavných oblastí: vysokohorská oblasť, oblasť stredohorí, nižších pohorí a kotlín a oblasť nížin (VAŠKOVÝCH 1977, 21).

Do kategórie vysokohorskej oblasti zaradujeme horské masívy, u ktorých vrcholy presahujú nadmorskú výšku 1500 m n.m. Túto podmienku spĺňajú masívy jadrových pohorí Malej a Veľkej Fatry. Ich najvyššie vrcholy sú Malý Fatranský Kriváň výškou 1669 m n.m. a Veľký Fatranský Kriváň 1711 m n.m. pre pohorie Malej Fatry a vrch Ostredok s nadmorskou výškou 1592 m n.m. pre masív Veľkej Fatry. Obe pohoria patria do komplexu Vnútrotných Západných Karpát. Vo vysokohorskej oblasti zohralo dôležitú úlohu zaľadnenie v období pleistocénu, ktoré výraznou mierou ovplyvnilo ráz reliéfu. Kryštálické jadro ako najstarší stavebný prvok, budované prevažne granitoidnými horninami (žuly, miestami kryštálické bridlice), tu vystupuje na povrch v súvislejších celkoch a miestami sa ponára pod sedimenty mladopaleozoicko–mezozoického obalu. V základoch obalu sú permské sedimenty. Mezozoická časť obalu pohorí je tvorená z kompletne vrstveného sledu od spodného triasu až do strednej kriedy (VAŠKOVÝCH 1977, 23). Spomenuté vrcholy pohorí isto neunikli pozornosti obyvateľov a je pravdepodobné že mohli hrať dôležitú úlohu v ich živote. Ako orientačné body slúžia dodnes, avšak prírodné podmienky v tejto oblasti môžeme považovať za nevhodné pre trvalejšie osídlenie ako v období ranného stredoveku, tak aj v neskorších obdobiach.

Oblasť stredohorí, nižších pohorí a kotlín je charakteristická zložitou geologickou stavbou predkvartérnych útvarov, členitým reliéfom a výskytom fluviálnych sedimentov vo forme riečnych terás ako aj proluviálnych a svahových sedimentov (VAŠKOVÝCH 1977, 50).

Oblasť zaberá najväčšiu časť zo skúmaného regiónu. Orograficky sa jedná o rôznorodý región do ktorého začleňujeme územia horských masívov, ktorých nadmorská výška nepresahuje 1500 m n.m. a horské kotliny. V oblasti sa nachádzajú okrem jadrových, flyšové a bradlové pásma. Flyš je horninový komplex vzniknutý sedimentáciou splavovaných hornín z dvíhajúceho sa kontinentu. Do vonkajšieho pásma flyšových pohorí stredohorskej oblasti patria Biele Karpaty, Javorníky a Beskydy. Flyš je charakteristický viacnásobným striedaním pieskovcov a ílovcov (VAŠKOVÝCH 1977, 50). Na jeho tvorbe sa podieľajú komplexy flyšových súvrství spolu so zlepenkami kriedového až paleogénneho veku. Naproti tomu bradlové pásmo vzniklo ako pás so šírkou maximálne 15 km, s komplikovaným tektonickým vývojom, oddeľujúcim vonkajšie flyšové a vnútorné jadrové pohoria Západných Karpát. Samotné bradlové pásmo sa nevyčleňuje ako samostatná geomorfologická jednotka, no od flyšového pásma Vonkajších Západných Karpát sa značne odlišuje okoskopicky aj litografickým zložením.

Charakteristickým znakom stredohorských oblastí sú výrazné kotliny. Ich vývoj je spojený s klenbovým zdvihom Karpát, v rámci ktorého sa niektoré ich časti dvíhali menej. Kotliny začali vznikať koncom paleogénu a začiatkom neogénu. Na základe ich najnižšej nadmorskej výšky sa kotliny delia na 3 skupiny. Medzi najnižšie položené kotliny s dnami nepresahujúcimi nadmorskú výšku 300 m n.m. možno počítať útvary Považského podolia. Z juhu do regiónu zasahujúcu Hornonitriansku kotlinu musíme priradiť do skupiny kotlin stredného pásma s nadmorskými výškami od 300 do 500 m n.m. Žilinská kotlina nachádzajúca sa medzi horskými chrbátmi pohorí Malej Fatry, Strážovskými vrchmi, Súľovskými vrchmi, Javorníkom a Kysuckou vrchovinou je tradične zaraďovaná do tejto skupiny. Jej geologické podložie je tvorené piesočnatými a štrkovými sedimentmi Váhu a jeho prítokov, ktoré vytvorili široké pásy riečnych nív a nízkych terás. Turčianska kotlina je najvyššie položenou kotlinou v regióne a patrí do tretej skupiny. Táto svojou rozlohou vymedzuje samotný región Turiec. Nachádza sa medzi celkami Malej a Veľkej Fatry. Bohaté ložiská vápenca s veľkým výskytom fosílií svedčí o existencii jazera alebo mora v eocéne.

V sledovanom regióne nie je možné jednoznačne identifikovať žiadnu nížinu. Podľa delenia výškových stupňov Slovenska by do tejto kategórie spadali oblasti v údoliach riek. Avšak tieto úzke pásy nie je možné označovať ako nížiny. Jedná sa o riečne terasy pokryté fluvialnými sedimentmi – sú spojovacími článkami vysokohorskej oblasti a oblasti nížin (VAŠKOVÝCH 1977, 70).

Geologickú skladbu regiónu reprezentuje v prostredí GIS vrstva GEO. Táto vzhľadom k veľkému počtu kategórií nebola použitá pre tvorbu modelu osídlenia. Vrstvu som použil na identifikovanie riečnych nív, ktoré slúžili ako východzie body pre vrstvu časovej vzdialenosti od nivných sedimentov¹ (TNIVA).

¹ Viac informácií o vrstve TNIVA v texte na strane 49.

Pedológia skúmaného regiónu

Najrozšírenejším typom pôd v analyzovanej oblasti so zastúpením až 56% sa ukázali kambizemné pôdy. Jedná sa o stredne úrodné pôdy, nie príliš vhodné na poľnohospodárske účely. Pri dostatočnej hrúbke ich vrstvy sú vhodné pre úzky sortiment plodín ako jačmeň či raž. Majú vysokú schopnosť zadržiavať vlhkosť a vzhľadom na ich výskyt vo svahovitých polohách sú často erodované. Sú najrozšírenejším pôdnym typom na území Slovenska, vyvinuli sa vo všetkých podnebných pásmach. V nižších nadmorských výškach nachádzame ich nasýtenú variantu (kambizeme nasýtené). Od nadmorskej výšky 600 m. n. m. potom začína prevládať kyslá varianta (kambizeme kyslé), (AGROPORADENSTVO.SK).

Druhým percentuálne vysoko zastúpeným typom sú rendziny. Jedná sa o horské až vysokohorské pôdy. Vyvinuli sa prevažne z hornín mezozoickej obalovej série kryštalinika. Túto sériu tvoria takmer výlučne vápence a dolomity. Nachádzame ich vo všetkých výškových aj klimatických pásmach v regióne. Jedná sa o pôdy s veľmi pomalým vznikom humusu a jeho nízkym obsahom, preto nie sú vhodné na poľnohospodársku činnosť (AGROPORADENSTVO.SK).


Výraznejšie zastúpenými skupinami, aj keď o mnoho menej, v porovnaní s predchádzajúcimi pôdami sú fluvizeme a pseudogleje. Pôvodným prirodzeným porastom fluvizemí boli v minulosti lužné lesy a nivné lúky (6%). Skladba fluvizemí sa môže meniť v závislosti od naplavovaného materiálu, preto aj obsah humusu a prípadné využitie pôdy je rôzne. Ide poľnohospodársky dobre využiteľné pôdy so širokou paletou uplatnenia (AGROPORADENSTVO.SK).

Zastúpenie pôd v regióne reprezentuje v prostredí GIS vrstva SOIL². Detailné informácie o počte a zastúpení jednotlivých kategórií poskytne tabuľka nižšie (Tab. 3). Na nasledujúcom obrázku (Obr. 3) vidno zjednodušenú reprezentáciu mapy pôdných typov podľa podskupín.

² Viac o vrstve SOIL v texte na strane 27.

VALUE	NAZOV	AREA_%	AREA_KM ²
1	kambizeme pseudoglejové nasýtené	10.50	902.60
2	kambizeme typické nasýtené až kyslé	6.64	570.84
3	kambizeme dystrické a kambizeme typické kyslé	19.34	1662.32
4	rendziny a kambizeme rendzinové	23.18	1991.97
5	fluvizeme typické karbonátové	2.49	214.37
6	pseudogleje typické a pseudogleje luvizemné nasýtené až kyslé	4.89	420.49
7	andozeme typické kyslé, kambizeme andozemné a kambizeme typické kyslé	0.35	30.03
8	rendziny vylúhované a kambizeme rendzinové	3.84	330.45
9	kambizeme typické kyslé	2.18	187.36
10	kambizeme dystrické	5.32	457.34
11	luvizeme typické a luvizeme pseudoglejové	1.06	91.45
12	hnedozeme luvizemné a luvizeme	0.90	77.38
13	fluvizeme glejové	1.34	115.56
14	ciernice typické	0.05	4.65
15	fluvizeme typické	2.43	209.19
16	podzoly typické	0.95	81.86
17	kambizeme pseudoglejové kyslé	2.07	178.27
18	hnedozeme typické	0.62	53.28
19	kambizeme pseudoglejové nasýtené a ciernice typické	0.06	5.35
20	hnedozeme pseudoglejové a pseudogleje	0.66	56.69
21	rendziny typické litické a rubefikované	0.10	8.50
22	ciernice typické karbonátové	0.60	51.79
23	kambizeme typické nasýtené	7.36	632.44
24	andozeme typické nasýtené, kambizeme andozemné a kambizeme typické nasýtené	0.19	16.13
28	podzoly kambizemné	0.99	85.07
29	luvizeme pseudoglejové	0.05	4.29
30	pararendziny, regozeme a kambizeme rendzinové	1.20	103.30
31	pseudogleje typické kyslé až pseudogleje stagnoglejové	0.07	5.68
32	rendziny vylúhované a rendziny organozemné	0.47	40.10
33	ciernice glejové	0.07	6.07

Tab. 3 – Zastúpenie typov pôd v regióne.



Obr. 3 – Mapa podskupín pôdných typov v regióne (SOIL).

Hydrológia

Dnešný charakter riečnej siete v oblasti úzko súvisí s geomorfologickým vývojom regiónu (Obr. 4). Celý regiónom preteká rieka Váh, ktorá je zároveň ťažiskovým tokom regiónu. Jeho prítoky tvoria pomerne hustú riečnu sieť. Popri Váhu medzi hlavné vodné toky v oblasti patria rieky: Kysuca, Nitra, Turiec.

Rieka Váh

Váh je najväčšia rieka regiónu ako aj najdlhšia rieka Slovenska. Vzniká spojením dvoch riek Biely a Čierny Váh, prameniach vo Vysokých Tatrách a pod Kráľovou Hoľou. Tečie od Tatier smerom na západ a pri Žiline sa otáča na juh. Za prvú zmienku o toku Bieleho Váhu je pokladaná zmienka o pohorí Balwak v texte arabského geografa Al-Idrisi-ho. Ten pod týmto názvom uvádza pohorie Tatier či celých Karpát, v ktorom pramenia dve rieky (Váh, Nitra alebo Hron) vtekajúce do Dunaja (PAULÍNY 1999, 154). Povodie Váhu zároveň definuje celú oblasť. Dĺžka jeho toku v regióne je 117,226 km. K jeho hlavným priamym prítokom patria riečky Turiec, Rajčiaka, Varínka a Kysuca. Ďalšie vodné toky v oblasti sú toky v Čierňanka a Teplica. Tieto toky, spolu s ostatnými menšími tvoria povodie Váhu (WIKIPEDIA.ORG 2011a).

Rieka Kysuca


Rieka Kysuca pramení na slovensko-moravskom pomedzí, blízko obce Makov. V dĺžke 66 km preteká obcami Vysoká, Raková a mestom Čadca. V blízkosti obce Krásno nad Kysucou priberá ľavý prítok Bystrica. K toku Váhu sa pripája v oblasti Žiliny. Na sútoku Váhu a Kysuce stojí zámok Budatín, miesto kde sa v minulosti vyberalo mýtno. Prvé písomné zmienky o mene rieky Kysuca pochádzajú z 13. storočia, kedy je v roku 1244 uvedená ako Kiszudcze (WIKIPEDIA.ORG 2011b).

Rieka Nitra

Rieka Nitra pramení v pohorí Strážovských vrchov na južnom okraji Malej Fatry, blízko obce Čičmany. Od prameňa ktorý sa nachádza v sledovanej oblasti preteká cez oblasť Ponitria smerom na juh v celkovej dĺžke 196 km. Tok rieky končí v blízkosti mesta Komárno, kde sa vlieva do Váhu a ten ďalej do Dunaja. Meno Nitra s najväčšou pravdepodobnosťou vzniklo skrátením pôvodného mena Nitrava vyskytujúceho sa v písomných prameňoch už v 9. storočí (WIKIPEDIA.ORG 2011c).

Rieka Turiec

Rieka Turiec tvorí svojim povodím Turčiansku kotlinu. Pramení v južnej časti pohoria Malá Fatra, odkiaľ severným smerom preteká celou Turčianskou kotlinou v dĺžke 66 km až do miesta svojho sútoku s riekou Váh pri meste Martin. Rieka dala názov celému regiónu - Turiec. Jej meno je možné identifikovať v názvoch viacerých obcí v oblasti (napr. Turčianske Teplice, Turčianske Kľačany, Turčiansky Peter a Michal atď.).



Obr. 4 – Rozmiestenie hlavných vodných tokov v oblasti.

Prírodné podmienky v skúmanej oblasti

Podnebie

Morfológia terénu a nadmorské výšky výrazne ovplyvnili klimatické podmienky v oblasti. V regióne prevládajú mierne teplé až chladné zóny s priemerným počtom letných dní - menším ako 50 (HRNČÁROVÁ 2002, mapa 27). V dolinách horného toku Nitry a stredného Váhu s nižšími nadmorskými výškami je možno pozorovať teplé, mierne vlhké podnebie s miernou zimou, s januárovými teplotami klesajúcimi maximálne k -3°C a počtom zimných dní nepresahujúcich 60. Denné tepelné maximum v tomto pásme dosahujú 25°C a počet letných dní za rok presiahne 50. S rastúcou nadmorskou výškou sa podnebie postupne ochladzuje a pribúda zrážok. Počet letných dní klesá a júlové teploty dosahujú maximálne 16°C . Rastie počet studených zimných dní a teploty v januári často klesnú pod hranicu -3°C . Vo vyšších nadmorských výškach potom môžeme pozorovať chladné až horské podnebie s letnými teplotami nepresahujúcimi 10°C a veľmi početnými zrážkami.

Vegetácia

Na základe peľových analýz rašelinísk, drevených uhlíkov a semien rastlín pochádzajúcich prevažne z archeologických výskumov je možné aspoň čiastočne zrekonštruovať vývoj vegetácie v glaciáli a postglaciáli. Poznatky o vegetácii z omnoho mladších období možno doplniť o historické pramene obsahujúce zmienky o flóre a vegetácii (KRIPPEL 1986, 18). Bohužiaľ, na území Slovenska nie je dostatok rašelinísk, ktoré by mohli uchovať detailnú informáciu o vegetačnom pokryte v minulom období a napomôcť k rekonštrukcii drevinovej skladby v jednotlivých obdobiach. Musíme sa uspokojiť so značne generalizujúcim obrazom vývoja vegetácie.

Od počiatku neskorej doby ľadovej a celej doby poľadovej je v analyzovanej oblasti hlavnou a najrozšírenejšou vegetačnou formáciou les. V období od počiatku staršej doby železnej približne po začiatok doby sťahovania národov dochádzalo k ničeniu a klčovaniu pôvodných pralesov. Táto činnosť prebiehala s takou intenzitou, že ich obnova prirodzenou cestou už nebola možná. Medzi prvým boli odlesnené nížinné polohy v nivách riek a niektoré kotliny (KRIPPEL 1986, 287).

V období včasného stredoveku nastáva pre les priaznivejšie obdobie. S prechodom na trojpoľný systém poľnohospodárstva nebolo potrebné odlesňovať ďalšie plochy. Ošípané a dobytok sa však naďalej pásol v lesnom poraste a hlavne v nízkych dubinách spôsoboval veľké škody (KRIPPEL 1986, 287).

Podobne ako klimatické pásma aj vegetácia v krajine je do značnej miery ovplyvnená morfológiou. Porasty možno rozdeliť do niekoľkých vegetačných stupňov (Tab. 4). Tie sa s rastúcou nadmorskou výškou menia od dubových nížin až po pásmo kosodrevín. Z hľadiska vegetačného krytu sú na sledovanom území najsilnejšie zastúpené stupne bukových (57%) a dubovo-bukových lesov (26%); (Tab. 16).

Vegetačný stupeň	Nadmorská výška (v m)	Ročné zrážky (v mm)	Vegetačné obdobie (v dňoch)
1. dubový	< 300	< 600	180
2. bukovo - dubový	200 - 500	600-700	165-180
3. dubovo - bukový	300 - 700	700-800	150-165
4. bukový	400 - 800	800-900	130-160
5. jedľovo - bukový	500 - 1000	900-1050	110-130
6. smrekovo - bukovo - jedľový	900 - 1300	1000-1300	90-120
7. smrekový	1250 - 1550	1100-1600	70-100
8. kosodrevinový	≥ 1500	≥ 1500	≥ 60

Tab. 4 – Vegetačné stupne na území Slovenska (zdroj forestportal.sk).

Zastúpenie jednotlivých kategórií potenciálnej vegetácie detailne zobrazuje tabuľka (Tab. 5). Jednoznačne prevládajúcim prvkom sú bukové (1) a dubovo – hrabové lesy (11).

VALUE	NAZOV	AREA_KM ²	AREA_%
1	Bukové (F) a jedlové (A) lesy kvetnaté	3297.41	38.36
2	Jedlové a jedlovo-smrekové lesy	174.29	2.03
3	Smrekové lesy cucoriedkové	37.25	0.43
4	Subalpínske kosodrevinové a trávinné vápnomilné spoločenstvá	0.09	0.00
5	Bukové kyslomilné lesy horské	295.44	3.44
6	Lužné lesy podhorské a horské	474.54	5.52
7	Smrekové lesy zamokrené	5.14	0.06
8	Bukové kyslomilné lesy podhorské	45.13	0.52
9	Lipovo-javorové lesy	24.82	0.29
10	Bukové kvetnaté lesy podhorské	614.41	7.15
11	Dubovo-hrabové lesy karpatské	1877.17	21.84
12	Lužné lesy nížinné	562.28	6.54
13	Bukové lesy vápnomilné	685.09	7.97
14	Dubové kyslomilné lesy	13.84	0.16
15	Dubové subxerothermofilné a borovicové xerofilné lesy	4.41	0.05
16	Dubovo-hrabové lesy lipové	157.39	1.83
17	Dubové nátržníkové lesy	83.22	0.97
18	Dubové xerothermofilné lesy submediteránne a skalné stepi	24.30	0.28
19	Dubovo-cerové lesy	58.49	0.68
20	Javorové horské lesy	85.14	0.99
21	Dubovo-hrabové lesy panónske	23.91	0.28
22	Subalpínske kosodrevinové a trávinné kyslomilné spoločenstvá	3.01	0.04
23	Smrekovo-borovicové lesy a ostrevkové spoločenstvá	13.27	0.15
24	Smrekové lesy vysokobylinné	23.46	0.27
25	Bukovo-borovicové lesy a ostrevkové spoločenstvá	0.99	0.01
26	Lužné lesy vrbovo-topolové	6.09	0.07
28	Slatiniská	3.24	0.04
29	Borovicové kyslomilné lesy a trávnaté porasty viatych pieskov	1.57	0.02

Tab. 5 – Zastúpenie lesných typov v regióne.

Účel prediktívneho modelovania

Skúmanie vzájomných priestorových vzťahov archeologických komponentov v snahe priblížiť sa pochopeniu sociálne-geografických súvislostí zaniknutých spoločenstiev je neodmysliteľnou súčasťou archeológie. (KUNA 2004, 445-490; NEUSTUPNÝ 2007, 113-120; VLACH 2010, 19).

Predikcia výskytu archeologických prameňov vo všeobecnosti predpokladá, že človeka v minulosti k výberu areálov vhodných pre osídlenie viedli také faktory, ktoré je dnešný človek schopný správne pochopiť a náležite spracovať (NEUSTUPNÝ 2000, 320). Pri tvorbe prediktívneho modelu teda predpokladáme, že vieme odhadnúť aké premenné sa podieľali na vzniku nami sledovanej distribúcie komponentov, ako aj fakt, že vieme odhadnúť, do akej miery sú tieto dôležitými. Výber vhodného miesta osídlenia samozrejme nezávisel iba na enviromentálnych či ekonomických faktoroch. Musíme počítať s možným ovplyvnením štruktúry osídlenia faktormi, ktoré nie je možné zrekonštruovať priamo z archeologických prameňov. Práve pomocou modelov založených na známych ekonomických a enviromentálnych hľadiskách možno pomôcť k odhaleniu a porozumeniu takým faktorom, ako sú možné kultúrne preferencie určitého prostredia či existencia nadkomunitných areálov (KUNA 1996, 584).

Potreba vyhodnotiť priestorové vzťahy medzi jednotlivými lokalitami a ich interakciou s georeliéfom skúmanej oblasti, ovplyvnila systém práce so základnými prameňmi a viedla k uplatneniu nasledovných postupov. Pričom formáty informačných zdrojov značne limitovali spôsob a použitie jednotlivých metód.

Metodika


Postup pri vytváraní modelu

Pri tvorbe modelu tvoríme zjednodušené koncepcie reálnych systémov, ktoré následne analyzujeme za účelom získania informácii o už zaniknutých systémoch. Aby boli tieto modely spoľahlivé, musia byť tvorené testovateľnými hypotézami (DANIELISOVÁ 2008). Pri predikcii sa do istej miery spoliehame na analógie známe z už objavených archeologických lokalít. Práve takýto induktívny spôsob práce, od známeho k neznámemu som zvolil pri analýze známych archeologických komponentov a ich interakcii s okolitou krajinou.

Postup tvorby modelu je možné rozdeliť do troch po sebe nasledujúcich fáz (Obr. 5). Prvou fázou je tvorba primárnych dát. V tejto formulujeme problém, stanovujeme základné hypotézy a zhromažďujeme vstupné dáta.

V druhej fáze sa tieto primárne vrstvy vzájomnými kombináciami, či aplikáciou nových procesov transformujú do podoby sekundárnych dát, ktoré následne dajú vzniknúť prvotnému modelu. Do tejto fáze môžeme zaradiť aj testovanie výkonu modelu a analýzu zákonitostí v umiestnení lokalít.

Vo finálnej fáze je model zlepšovaný pridaním nových dát a vytvorený model nový. Táto fáza zacyklí celú tvorbu modelu opäť k druhému kroku po ktorom je nutné model znova otestovať a v prípade nových dát vytvoriť nový vylepšený model. Tvorba modelu je tak v podstate nikdy nekončiacou procedúrou (DALLA BONA 2003).



Obr. 5 – Diagram postupou pri predikcii

Pri tvorbe modelu som používal hlavne dvojicu programov zameraných na prácu s geograficko-informačnými zdrojmi. Prvý z nich, program IDRISI (EASTMAN 2006), tento som použil na výpočet väčšiny sekundárnych vrstiev a na väčšiu časť práce s nimi a samotnú tvorbu modelu. V programe ArcGIS (ESRI 2011) som rastrové vrstvy kombinoval s vrstvou archeologických bodov a vytváral obrazovú dokumentáciu.


Na výpočet štatistických analýz som použil program STATISTICA (STATSOFT 2010), GraphPad (GRAPHPAD 2007a) a balík programov R (TEAM 2010).

Textová časť spolu s tabuľkami vznikla v prostredí softvérového balíku Office 2003 (MICROSOFT 2002).

Fáza 1 – tvorba primárnych vrstiev

V počiatočnej fáze som zhromaždil dáta potrebné pre tvorbu modelu, z ktorých boli vytvorené primárne vrstvy (Obr. 6). Jedná sa o súbor vrstiev obsahujúcich základné informácie o regióne z ktorých som v práci vychádzal.

Vo fáze zberu dát a ich prvotného spracovania bolo nutné použiť rad informačných zdrojov (napr. geografické, botanické a geologické mapy či súbor archeologických komponentov). Aj napriek skutočnosti, že nie všetky informácie v nich obsiahnuté možno považovať za faktory ovplyvňujúce polohu archeologických nálezov, každý z týchto informačných zdrojov prispel k poznaniu skúmaného regiónu (NEUSTUPNÝ 2000, 323).



Obr. 6 – Diagram pracovného postupu pri tvorbe modelu.

Archeologické informačné zdroje

Základom pre vznik modelu bol vrstva vzniknutá použitím katalógu lokalít zhromaždeného Petrom Milom v jeho diplomovej práci (MILO 2000). P. Milo v práci vychádzal jednak z publikovanej literatúry do roku 1999 a z archívu nálezových správ SAV. V tejto práci je teda hlavným zdrojom súpis lokalít v diele Pramene k dejinám osídlenia Slovenska z konca 5. až 13. storočia (BIALEKOVÁ 1992) a rovnako aj jednotlivé nálezové správy. Katalóg lokalít som porovnal s publikovanou literatúrou po roku 2000. Ukázalo sa, že v mnou skúmanom regióne sa za posledných 10 rokov neobjavil žiadny nový archeologický komponent splňujúci predpoklady pre zaradenie do analýz. V tejto fáze práce vznikla aj bodová vrstva v prostredí GIS. K prevodu súradníc z katalógu P. Mila (2000) do súradnicového formátu S-JTSK bol použitý program Unitrans (BEČVÁŘ 2007).

Geografické informačné zdroje

Vojenská topografická mapa

V archíve nálezových správ SAV v Nitre je dlhoročnou praxou popis lokalizácie terénnych aktivít pomocou topografických máp v mierke 1:25 000. Toto mapové dielo začalo vznikať po druhej svetovej vojne, pomocou metódy leteckej fotogrametrie. Pôvodne bolo určené pre technicko – hospodárske účely Československej Ľudovej Armády a bolo využívané predovšetkým teritoriálnymi zariadeniami vojenskej správy. Mapové dielo bolo vydané roku 1959. Jeho najväčšia mierka bola 1 : 25 000. Pre dielo bolo použité Gauss – Krügerovo konformné zobrazenie v 6° zobrazovacích pásoch, kde referenčnú plochu tvorí Krasovského elipsoid (RADĚJ 2001). Súradnicový systém bol označený ako systém 1952 (S-52). Os Y bola vložená do priameho obrazu rovníku a je kladná smerom k východu. Os X je priamym obrazom osového poludníku s kladnými hodnotami smerom na sever. V súčasnosti sa používa spresnený variant S-42. So vstupom do NATO armáda SR prechádza na medzinárodný systém WGS-84, ktorého súradnicový systém je na najnovších edíciách pritláčaný na mapy. Klad a označenie mapových listov vychádza z kladu listou Medzinárodnej mapy sveta v mierke 1 : 1 000 000. Rozmery mapy v mierke 1 : 1000 000 sú 6° zemepisnej dĺžky a 4° zemepisnej šírky. Pre zemepisnú dĺžku sú poludníkové pásy číslované od 1 po 60, zatiaľ čo zemepisná šírka sa značí písmenami A až V smerom od rovníka (RADĚJ 2001). Mnou skúmané územie leží na mapovom liste M-34.

Obsah mapy tvoria body geodetických polohových základov, terénu kóty, zemepisná a kilometrová sieť, popisné a mimoriadne údaje, polohopis (značený čiernou farbou), vodstvo (modrá farba), vrstevnice (s krokom 5 metrov), terénne útvary (hnedá farba), vegetačný pokryv (zelená farba), komunikácie a štátne hranice (červená).

Výsledná presnosť mapového diela na vytlačku mapy bola stanovená na $\pm 8,5$ m na osi X $\pm 8,8$ m na osi Y (PAVLICA a kol. 1958, ; RADĚJ 2001). V prípade lokalizácie archeologických nálezísk, však s takouto presnosťou nemôžeme počítať. Vynášanie na mapu sa robí v značnom časovom odstupe a samotná presnosť veľmi záleží od zručnosti a skúsenosti archeológa.

Výškopisný model územia (DEM)

Jedná sa o základnú vrstvu všetkých geografických premenných. Bola vytvorená z digitálneho modelu SR (METI a kol. 2009). Pri štúdiu prameňov sa môžeme stretnúť s nejednoznačnosťou v terminológii označovania modelovaných reliéfov. Existuje množstvo termínov a skratiek. (ČULÁKOVÁ - OFÚKANÝ 2003).

Základný termín digitálny výškový model (DVM) je prekladom z anglického digital elevation model (DEM). Predstavuje povrch s plynulo sa meniacou hodnotou premennej nadmorskej výšky. Jedná sa o digitálne topografické zobrazenie povrchu, ktoré môže mať formát vrstevníc, diskretných výškových bodov, línií terénnych zlomov alebo pravidelnej mriežky. Za jeho podskupiny sú považované: digitálny model terénu (angl. digital terrain model – DTM) a digitálny model povrchu (angl. digital surface model - DSM).

Digitálny model povrchu vzniká automatizovaným vyhodnocovaním leteckých snímok a reprezentuje výškové údaje všetkých objektov na nich zobrazených. Zobrazuje teda okrem zemského povrchu aj objekty na ňom ležiace (napr. budovy a lesné porasty). Naproti tomu digitálny terénny model zobrazuje iba zemský povrch, bez stavieb a vegetačného krytu. V rámci archeológie nachádza využitie práve druhý spomenutý model (DTM). V českej kartografii je pre tento model zaužívaný termín digitálny model reliéfu – DMR. Z ďalších používaných termínov treba spomenúť, digitálny model územia – DMÚ. Jedná sa o základnú bázu geografických dát a súbor programových prostriedkov ku zberu, spracovaniu, aktualizácii a distribúciu geografickej informácie o území (ČULÁKOVÁ - OFÚKANÝ 2003).

Pôvodnú vrstvu DEMu, uloženú vo formáte Double (formát desatinných čísel) som previedol do formátu Integer (formát celých čísel). To umožnilo v programe ArcGIS vypočítať hodnotu mediánu a vytvoriť atribútovú tabuľku s počtami buniek pre príslušnú hodnotu.

Tento krok pomohol vizualizácii a štatistickému popisu vrstvy nadmorských výšok. Prevodom desatinných čísiel na celé zanikli jemné rozdiely medzi bunkami v rádoch desiatok centimetrov. Tie sú však do veľkej miery výsledkom interpolácie a na celkovú presnosť modelu nebudú mať vplyv. Testy DMR s podobným rozlíšením (veľkosť bunky 30m) poukazujú na vertikálne presnosti v rozmedzí 1 m do 25 m (ČULÁKOVÁ - OFÚKANÝ 2003, ; METI a kol. 2009).


Geologická mapa (GEO)

Prvá verzia tejto spojitkej digitálnej mapy vznikla v rámci projektu: Digitálna geologická mapa Slovenskej republiky v M 1 : 50 000, ktorého riešiteľom je Š. Káčer a kol., 2005 (GEOLOGY.SK 2010). Mapa predstavuje aktuálny stav poznatkov o základnom štruktúrnom členení a geologickej stavbe územia Slovenska. Z 80 % vychádza zo základných geologických máp v mierke 1 : 25 000 a regionálnych geologických máp v mierke 1 : 50 000 zostavených v r. 1963 – 1992 (HRNČÁROVÁ 2002, 327). Okrem plošných, líniových a bodových informácií geologickej mapy sú dostupné nasledovné samostatné vrstvy: zoznam použitých podkladov, kategorizácia (vrstva kvality), prehľad mapovania a štruktúrna schéma.

Z plošných informácií digitálnej mapy sú dostupné nasledovné informácie: jednotná legenda, pôvodná legenda, charakteristika a výskyt jednotlivých litotypov pre celé územie SR (ANTALÍK - BYSTRICKÁ 2009). Digitálnu geologickú mapu SR som pre účely diplomovej práce získal z Štátneho geologického ústavu Dionýza Štúra (ŠGÚDŠ) v Bratislave.

Mapa potenciálnej prirodzenej vegetácie (FLORA)

Potenciálna prirodzená vegetácia je výrazom súčasného ekologického potenciálu krajiny (HRNČÁROVÁ 2002, 327). Predstavuje rastlinstvo, ktoré by sa postupne vytvorilo na území Slovenskej republiky za predpokladu, že by človek jeho vznik a šírenie svojou činnosťou prestal ihneď ovplyvňovať (Obr. 7). Prírodné podmienky Slovenska by dali vzniknúť až na malé výnimky súvislej lesnej vegetácii. Jedná sa o digitalizovanú podobu mapy v mierke 1:500 000. Z hľadiska zachovalosti môžeme vegetáciu na území Slovenska považovať za pomerne neporušenú. K roku 2006 pokrývali takmer 41 % územia Slovenska lesy.



Obr. 7 – Mapa potenciálnej prirodzenej vegetácie na sledovanom území (FLORA).

číslo	popis	číslo	popis
1	Bukové (F) a jedľové (A) lesy kvetnaté	15	Dubové subxerothermofilné a borovicové xerofilné lesy
2	Jedľové a jedľovo-smrekové lesy	16	Dubovo-hrabové lesy lipové
3	Smrekové lesy cucuriedkové	17	Dubové nátržníkové lesy
4	Subalpínske kosodrevinové a trávinné vápnomilné spoločenstvá	18	Dubové xerothermofilné lesy submediteránne a skalné stepi
5	Bukové kyslomilné lesy horské	19	Dubovo-cerové lesy
6	Lužné lesy podhorské a horské	20	Javorové horské lesy
7	Smrekové lesy zamokrené	21	Dubovo-hrabové lesy panónske
8	Bukové kyslomilné lesy podhorské	22	Subalpínske kosodrevinové a trávinné kyslomilné spoločenstvá
9	Lipovo-javorové lesy	23	Smrekovo-borovicové lesy a ostrevkové spoločenstvá
10	Bukové kvetnaté lesy podhorské	24	Smrekové lesy vysokobylinné
11	Dubovo-hrabové lesy karpatské	25	Bukovo-borovicové lesy a ostrevkové spoločenstvá
12	Lužné lesy nížinné	26	Lužné lesy vrbovo-topolové
13	Bukové lesy vápnomilné	28	Slatiniská
14	Dubové kyslomilné lesy	29	Borovicové kyslomilné lesy a trávnaté porasty viatych pieskov

Mapa pôdných typov (SOIL)

Zastúpenie pôdných jednotiek na území Slovenska je vyjadrené pôdnymi asociáciami tvoriacimi mapové jednotky. Prezentyujú dominanciu zastúpenia pôdných jednotiek v asociácii a niektoré ďalšie prvky, predovšetkým pôdotvorné substráty a v krátenej klasifikácii tiež extrémnu zrnitosť pôd (ľahké až ťažké). Geneticky príbuzné jednotky sú zoradené do skupín pôdných asociácií. Mapa vznikla generalizáciou kartografických materiálov zo všetkých pôdných prieskumov a mapovaní od r. 1960 (HRNČÁROVÁ 2002, 327). Do digitálnej podoby bola prevedená v mierke 1: 500 000.

Fáza 2 - tvorba sekundárnych vrstiev a ich testovanie

Vrstva archeologických komponentov

Primárnu vrstvu komponentov som prepracoval tak, aby jednotlivé záznamy vo vrstve obsahovali informácie iba o jednom archeologickom komponente. Odstránil som tak záznamy o písomných zmienkach nachádzajúcich sa v primárnej vrstve. Základná štruktúra tabuľky vychádza z práce P. Mila (2000), bola však upravená za účelom jednoduchšieho filtrovania a neskorších analýz. Tabuľka obsahuje nasledovné polia:

IDKomp:

Pole predstavuje jedinečný, pôvodný, identifikátor komponentu spoločný pre obe práce. Toto pole obsahujú všetky tabuľky, ktoré sú prostredníctvom neho prepojené.

NazovObce:

Obsahuje Názov katastrálneho územia, do ktorého komponent patrí.

CastObce:

Miestna časť územia, na ktorom sa komponent nachádza.

Poloha:

Tradičné pomenovanie miesta s komponentom.

Datovanie:

Pri chronologickom zaradení lokalít som použil pôvodnú terminológiu použitú v práci P. Mila (2000). Táto je do veľkej miery ovplyvnená obdobím, kedy bol nález uskutočnený. Jedná sa zväčša iba o relatívne chronologické zatriedenie komponentov do jednotlivých období, pričom väčšina záznamov pochádza z povrchových prieskumov. Tieto sú často chronologicky nevýrazné a sú zaradené do širšieho časového rámca. V literatúre je často možno nájsť lokality či komponenty datovane rámcovo do stredoveku, slovanského obdobia či do doby Veľkej Moravy. V práci som sa sústredil iba na komponenty z obdobia, medzi 7. - 11. storočím.


Za účelom vytvorenia prehľadu datovania jednotlivých komponent, ktoré poskytuje nasledujúca tabuľka (Tab. 6), som pôvodnú terminológiu previedol do matice binárneho formátu. V tejto matici riadky predstavujú jednotlivé komponenty a stĺpce jednotlivé storočia. Nižšie v grafe (Graf 2) je vidieť zastúpenie jednotlivých typov komponent.

	6. st.	7. st.	8. st.	9. st.	10. st.
SI	1	3	9	67	41
PO	0	0	11	24	7
INE	0	0	1	9	5
HR	0	0	1	12	9
CELKOM	1	3	22	112	62

Tab. 6 – Zastúpenie jednotlivých typov komponentov v rámci storočí. SI-sídliisko, PO – pohrebisko, INE- ostatné funkcie komponenty, HR – hradisko

Kvalita Datovania:

Pole predstavuje subjektívnu charakteristiku, mieru spoľahlivosti datovania, ktorá čiastočne vychádza z poľa Badanie. Tento vzťah možno vidieť v tabuľke nižšie (Tab. 7).



Graf 1 – Rozloženie kategórií rôznej kvality datovania v súbore archeologických komponentov.

V kategórii s najvyšším predpokladom správneho datovania (kat. 1) sú väčšinou zastúpené jednotlivé druhy archeologických výskumov. Naproti tomu v kategóriách, u ktorých je chronologické zaradenie komponentu neisté (kat. 2 a kat. 3) dominujú práve nálezy z povrchových prieskumov.

KvDat	NN	PP	PS	SV	ZiV	ZV	Celkom
1	4	0	3	12	13	13	45
2	4	35	16	1	6	5	67
3	3	13	0	0	1	2	19
Celkom	11	48	19	13	20	20	131

Tab. 7 - Vzájomný vzťah medzi poľami kvalita datovania a badanie.³

Badanie:

V tomto poli sú uvedené jednotlivé typy spôsobu objavenia komponentu. Kvalita celej pramennej bázy je podriadená spôsobu získania informácií o náleze.

Jednotlivé heslá z katalógu lokalít (MILO 2000) som reklasifikoval do nových kategórií a odstránil neštandardné zápisy. Pôvodný počet 20-tich kategórií som zúžil na 6. U nejednoznačných hesiel (NN/ZV, PP/ZiV) som vybral heslo zodpovedajúce spôsobu, u ktorého je predpoklad vyššej pravdepodobnosti správneho chronologického zaradenia nálezu. Tento postup som založil na predpoklade dodatočného spresnenia datovania komponentu práve týmto spôsobom.

Spôsob objavenia komponenty			
Náhodný nález	NN	11	8%
Povrchový prieskum	PP	48	37%
Prieskum stavby	PS	19	15%
Systematický výskum	SV	13	10%
Zisťovací výskum	ZiV	20	15%
Záchranný výskum	ZV	20	15%

Tab. 8 - Zastúpenie spôsobov objavenia komponentu.

³ Skratky použité v tabuľke (Tab. 7) vysvetľuje tabuľka (Tab. 8)

Archeologické bádanie v regióne som rozdelil do dvoch skupín, na prieskumy a výskumy. Do kategórie prieskumov zaradujem: náhodný nález (NN), povrchový prieskum (PP) a prieskum reliktov stavby(PS). Táto kategória v regióne dominuje (60%) oproti kategórii výskumov: systematický (SV), zisťovací (ZiV), záchranný (ZV).

Z tabuľky (Tab. 8) vyplýva, že väčšina záznamov pochádza z povrchových zberov. Tento spôsob zväčša odhalí existenciu sídliskových komponentov na otvorených poľnohospodárskych plochách. Sleduje distribúciu a koncentrácie archeologických artefaktov v priestore (KUNA 2004, 305).

Vo väčšine prípadov sa nejedná o systematické povrchové zbery. Tieto sú svojou podstatou skôr blízke náhodným nálezom, s tým rozdielom, že boli vykonané poučenou osobou alebo na základe predchádzajúceho náhodného nálezu. Vo veľkej väčšine prípadov je materiál z prieskumov chronologicky málo citlivý, s čím súvisí jeho slabá schopnosť datovania. Problematika datovania nálezových celkov z povrchových zberov je však nad rámec predkladanej práce.

Prieskumy reliktov stavieb sú špecifickým druhom povrchového prieskumu založeného na identifikácii terénnych útvarov (KUNA 2004, 237). Týmto spôsobom bola zistená veľká časť mohylníkov na sledovanom území.


Archeologické výskumy v regióne sú čo do kvality datovania oveľa spoľahlivejším zdrojom. Ich podiel v rámci celkového bádania je oveľa priaznivejší ako v prípade oblasti Záhoria (Tab. 9).

Počet komp	Bádanie	% zastúpenie
436	prieskum	74%
92	neuvádzaný	16%
64	výskum	11%


Tab. 9 – Zastúpenie spôsobov bádania v regióne Záhorie (TENCER 2008).

Aktivita:

V tomto poli je uvedená predpokladaná funkcia komponentu (Obr. 8). Pôvodné heslá v katalógu P. Mila (2000) som zjednodušil a zjednotil do 4 kategórii. Ako komponenty so sídelnou aktivitou som po kódom „SI“ označil sídliska a výrobné objekty. Kód „PO“ som použil pri komponentoch s predpokladanou pohrebnou a nesídelnou aktivitou: mohylník, mohyla, kostrové pohrebisko a hrob kostrový. Kategória označená ako „INE“ zahrnovala ojedinelý nález a depot. Komponenty s charakterom centrálnych sídlisk a opevnených polôh som označil kódom „HR“.



Graf 2 – Zastúpenie jednotlivých druhov komponentov v rámci storočí.



Obr. 8 – Prehľad komponentov v skúmanom regióne roztriedených podľa predpokladanej aktivity.

X:

Geografická súradnica v systéme S-JTSK.

Y:

Geografická súradnica v systéme S-JTSK.


Výsledná vrstva 131 komponentov bola na základe geografických súradníc zobrazená v systéme S-JTSK. Takto vzniknutú vrstvu naďalej chápem ako archeologické body v zmysle Neústupného metódy (NEUSTUPNÝ 1986, 533), ako diskkrétne priestorovo obmedzené časti archeologickej skutočnosti (DRESLER - MACHÁČEK 2008, 169).

Vrstvy geografických premenných

Základom pre všetky priestorové analýzy bola vrstva digitálneho výškopisného modelu reliéfu o veľkosti bunky 30 m (Obr. 1). Z tohto rastrového podkladu vznikli za pomoci programov IDRISI a ArcGIS vrstvy: vrstva prevýšenia terénu v okruhu 150 m, sklonu svahu a jeho orientácie na svetové strany, ďalej vrstva obsahujúca informácie o konvexnosti či konkávnosti terénu a vrstva, ktorej index predstavuje mieru zvlhnutia pôdy. Rozlíšenie každej z novovzniknutých rastrových vrstiev bolo zhodné s rozlíšením výškopisného modelu reliéfu (30m).

Pri induktívnom prístupe k tvorbe modelu je bežnou praxou ovzorkovať vrstvy obsahujúce modelotvorné faktory bodovou vrstvou známych komponent. Takto získané hodnoty však nemožno považovať za reprezentatívne, pretože komponent nemá podobu bodu a spravidla pokrýva plochu väčšiu ako je veľkosť jednej bunky (v mojom prípade 30 x 30 m – 9 árov či 900m²). V snahe zmenšiť takto vzniknutú chybu som vrstvy premenných upravil filtrom, ktorý spriemeruje hodnoty v oblasti 5 x 5 buniek. Hodnoty vstupujúce to procesu tvorby modelu tak nie sú iba hodnotami nachádzajúcimi sa na území jednej bunky, ale priemerom hodnôt celej oblasti 150 m okolo komponenty. Týmto krokom som zároveň znížil možné riziko chybnnej lokalizácie komponenty (JASIEWICZ - HILDEBRANDT-RADKE 2009, 2099).

Všetky vrstvy so spojitými premennými (TABULKA) som pomocou nástroja Focal statistic upravil priemerovacím filtrom s veľkosťou okna hľadania 5 x 5 buniek. Výsledkom bola séria upravených vrstiev, kde hodnota bunky ležiacej v strede štvorca so stranou 5 buniek (150 m) zodpovedala priemernej hodnote buniek v tomto štvorci (Obr. 9).




Obr. 9 – Postup pri aplikácii filtra v nástroji Focal Statistic (ESRI)


Pre tvorbu modelu som vybral nasledovné premenné:

LR150

Vrstva lokálneho prevýšenia by mala vo vzťahu s výskytom archeologických komponent odhaliť snahu týchto komponent nachádzať sa „čo najvyššie“, „čo najnižšie“ alebo medzi tým (KUNA 2006, 90). Vznikla z upraveného digitálneho modelu reliéfu pomocou nástroja Focal statistic ako rozdiel maximálnej a minimálnej hodnoty vo vzdialenosti 150 m (Obr. 10). Rozdiel medzi lokálnom maximom a minimom predstavuje rozptyl hodnôt v metroch a vertikálnu diverzitu terénu (DANIELISOVÁ 2008, 142). Nasledujúci graf (Graf 3) predstavuje odhad jadrovej hustoty pravdepodobnosti vrstvy LR150. Graf vznikol v programe R (TEAM 2010). Tento typ grafu som použil pre zobrazovanie odhadu jadrovej v priebehu celej práce. Krivka zobrazuje priebeh odhadu hustoty vybraného súboru. Popisok po vodorovnou osou „N“ predstavuje počet záznamov z ktorých bol odhad vypočítaný. Krátke zvislé čiarky reprezentujú rozloženie hodnôt v súbore archeologických komponentov.



Obr. 10 – Vrstva lokálneho prevýšenia v kruhu 150m.



Graf 3 – Odhad jadrovej hustoty pravdepodobnosti hodnôt vo vrstve LR150.

ASPECT

Ďalšou vrstvou bola vrstva orientácie svahu. Táto určuje odklon najstrmšie klesajúceho svahu od severného smeru. Vrstva nadobúda hodnôt 0°- 360° v smere hodinových ručičiek od severu s hodnotou 0°, východu s hodnotu 90°, 180° pre juh, 270° pre západ a 360° opäť pre sever. Hodnoty -1 sú určené pre bunky bez klesajúceho svahu, teda roviny (ESRI 1999-2010).

Z tejto vrstvy som pomocou reklasifikácie v Single-Map Algebra vypočítal uhlovú vzdialenosť od severného smeru. Podľa výrazu nižšie (Výraz 1) som od hodnôt väčších ako 180 odpočítal 360 a dostal tak škálu hodnôt od 0 do 180. V novovzniknutej vrstve hodnota 0 predstavuje presnú orientáciu na sever a hodnota 180 na juh. Týmto prepočtom som znemožnil presnejšie odlíšenie orientácie západ – východ, ale zároveň som zjednotil hodnoty udávajúce severný smer.

$$\text{aspect180} = \text{con}(\text{aspect360} > 180, 360 - \text{aspect360}, \text{aspect360})$$

Výraz 1 – Výraz pre výpočet uhlovej vzdialenosti od severného smeru.


Pri kvantitatívnom vyhodnocovaní je nevýhodou, že aj napriek nepatrnému rozdielu v orientácii buniek s hodnotami 359° a 1° na svetové strany, je ich rozdiel na stupnici od 0 do 360 (zaokrúhlené) obrovský. Ako príklad môže poslúžiť nasledujúca tabuľka (Tab. 10) predstavujúca rozloženie archeologických komponent na týchto dvoch vrstvách. Hodnota mediánu pri vrstve BASPECT360⁴ je 211.41 čo predstavuje JJZ smer. Pri vrstve BASPECT180⁵ je mediánu 87, čo predstavuje orientáciu na východ alebo západ. Rozdiel v rozložení možno pozorovať aj v nasledujúcom grafe odhadu jadrovej hustoty (Graf 4).

	Valid N	Mean	Median	Minimum	Maximum	Std.Dev.
BASPECT360	131	201.11	211.41	63.15	333.92	65.24
BASPECT180	131	88.79	87	2.72	174.52	37.51

Tab. 10 – Rozloženie súboru komponentov v vrstve BASPECT360 a BASPECT180.


⁴ ASPECT360 predstavuje spriemerovanú vrstvu orientácií na všetky svetové strany.

⁵ BASPECT180 predstavuje spriemerovanú vrstvu uhlovej vzdialenosti od severného smeru.




Graf 4 – Porovnanie odhadu jadrovej hustoty súborov BASPECT360 a BASPECT180.

Pri spracovaní vrstiev orientácií svahov sa ukázalo, ako veľmi záleží na kvalite vstupného rastru (DEM) a na zvolenom postupe. Pri práci som zvolil postup načrtnutý diagramom (Obr. 12). Zo zvoleného výškopisného modelu som vypočítal vrstvu orientácií, tu som reklasifikáciou upravil na vrstvu uhlovej vzdialenosti od severu. Vo výsledku som vrstvu upravil priemerovým filtrom 5x5 (Obr. 11).




Obr. 11 – Uhl'ová vzdialenosť od severného smeru.



Obr. 12 – Postup pri tvorbe vrstvy RBA180.

Rozhodol som sa otestovať rozdiel vo výsledných rastroch pri použití odlišných postupov pri ich tvorbe. Pri tvorbe prvého rastra (RBA180) som postupoval podľa diagramu na obrázku vyššie (Obr. 12). Druhý raster (BRA180) vznikol postupom zobrazeným v diagrame z obrázku dole (Obr. 13).



Obr. 13 – Postup pri tvorbe vrstvyBRA180.

Vytvoril som súbor testovacích bodov, ktoré šachovnicovo pokryli celú skúmanú oblasť. Ich vzájomná vzdialenosť bola 1 km. Následne som týmto súborom ovzorkoval obe vrstvy uhlových vzdialeností a výsledky porovnal v programe GRAPHPAD. Ani jeden zo súborov nepotvrdil predpoklad o normálnom rozložení. Studentov párový t-test aj jeho neparametrický variant, Wilcoxonov zmanienkový poradový test (HENDL 2006) potvrdili rozdielnosť súborov na hladine významnosti 0.05. Výsledky sú ako možno vidieť v tabuľke, štatisticky odlišné.


	sampleRBA180	sampleBRA180
Number of values	8592	8592
Minimum	2.36	1.64
25% Percentile	77.92	51.37
Median	115.1	90.48
75% Percentile	148	126.8
Maximum	180	177.2
Mean	111.1	89.48
Std. Deviation	43.16	44.6
Std. Error	0.4656	0.4812
Lower 95% CI	110.2	88.53
Upper 95% CI	112	90.42
KS normality test		
KS distance	0.06253	0.05465
P value	P<0.0001	P<0.0001
Passed normality test (alpha=0.05)?	No	No
P value summary	***	***
D'Agostino & Pearson omnibus normality test		
K2	1538	3711
P value	P<0.0001	P<0.0001
Passed normality test (alpha=0.05)?	No	No
P value summary	***	***

Tab. 11 – Výsledky testov normality súborov sampleRBA180 a sampleBRA180.

sampleBRA180 vs sampleRBA180		
	Wilcoxon signed rank test	Paired t test
P value	P<0.0001	P<0.0001
Exact or approximate P value?	Gaussian Approximation	
P value summary	***	***
Are medians signif. different? (P < 0.05)	Yes	Yes
One- or two-tailed P value?	Two-tailed	Two-tailed
Sum of positive, negative ranks	21800000 , 0.0000	t=56.48 df=8591
Number of pairs	8592	

Tab. 12 – Výsledok porovnávania stredných hodnôt súborov sampleBRA180 a sampleRBA180.

Rozdiel vo vrstvách je spôsobený umiestnením priemerového filtra v procese. Výrazné zmeny v hodnotách nastávajú práve v miestach s konkávnym a konvexným susedstvom. Ak aplikujeme priemerový filter pred prepočtom vrstvy na vrstvu uhlovej vzdialenosti, môže priemerná hodnota v susedstve prekročiť hranicu 180. Po prepočte na uhlovú vzdialenosť potom bunka nadobudne hodnotu okolo 0 a teda orientáciu svahu severným smerom. Oproti tomu, ak by sa pôvodný súbor pred vyhladením filtrom upravil na uhlovú vzdialenosť priemerná hodnota susedstva by severný smer nenaznačovala. Nasledujúci graf (Graf 5) zobrazuje odlišné rozloženie hodnôt v súboroch oboch vrstiev (RBA180 a BRA180).



Graf 5 – Porovnanie odhadu jadrovej hustoty vrstiev RBA180 (červená) a BRA180 (čierna).


K hodnotám buniek v týchto vrstvách je treba pristupovať veľmi opatrne. Vo viacerých prípadoch sa, že v oblastiach s minimálnym prevýšením, výpočet vrstvy orientácii neposkytuje relevantné informácie⁶. Algoritmus použitý na tento výpočet hľadá vždy najstrmší svah, čo v závislosti na presnosti vstupných dát môže predstavovať svah z

⁶ P. Dresler ústne zdelenie, január 2011.


praktického hľadiska zanedbateľný, či nepozorovateľný. Taktiež rozdiely v orientácii v rádoch stupňov sú zanedbateľné.

SLOPE

V prediktívnom modelovaní už tradične používaná premenná svažitosti terénu (DANIELISOVÁ 2008, ; DRESLER - MACHÁČEK 2008, ; GOLÁŇ 2001, ; KUNA 2006) vznikla aplikácií ArcGIS (Obr. 14). Táto pre každú bunku vstupného rastra identifikuje najstrmšie klesajúci svah (ESRI 1999-2010)




Obr. 14 – Vrstva svažitosti.



Graf 6 – Odhad jadrovej hustoty pravdepodobnosti hodnôt z vrstvy SLOPE.

TCI


Hodnota tejto premennej udáva potenciálne zamokrenie oblasti (Obr. 16). Vysoké hodnoty tohto indexu identifikujú polohy ležiace v blízkosti vodných tokov a v nižších polohách povodí. Naopak, polohy ležiace v blízkosti rozvodí alebo polohy vzdialené od vodných tokov vykazujú nízke hodnoty tohto indexu (KOPECKÝ - ČÍŽKOVÁ 2010, 450). K výpočtu indexu som použil jeden z modelov (Obr. 15) zo súboru nástrojov Topographical Tools (JENNESS) pre ArcGIS. Tento nástroj pri výpočte hodnôt vychádza zo vzorca (Výraz 2).



Obr. 15 – Model výpočtu vrstvy TCI (JENNESS a kol. 2010).


$$TCI = \ln\left(\frac{As}{\tan \beta}\right)$$

Výraz 2 – Vzorec použitý k výpočtu indexu TCI (BEVEN - KIRKBY 1979, 48; KOPECKÝ - ČÍŽKOVÁ 2010, 450).



Obr. 16 – Vrstva potenciálneho zamokrenia oblasti.


V tomto vzorci α predstavuje spádovú plochu (východiskovou vrstvou je raster akumulácie vodných tokov predstavujúci tendenciu bunky prijať vodu zo svahu) a β je jej sklon (tendencia bunky vodu stratiť). Index teda v relatívnej miere zachycuje schopnosť pôdy dlhodobo zadržiavať vlahu (KOPECKÝ - ČÍŽKOVÁ 2010, 450). Táto vlastnosť môže byť dôležitou pri výbere miesta osídlenia a polí (JASIEWICZ - HILDEBRANDT-RADKE 2009, 2106). Do istej miery môže suplovať tradične užívanú premennú vzdialeností od vodných tokov (DANIELISOVÁ 2008, ; DRESLER - MACHÁČEK 2008). Rozloženie hodnôt vo vrstve zobrazuje nasledujúci graf (Graf 7).



Graf 7 – Odhad jadrovej hustoty pravdepodobnosti hodnôt vo vrstve TCI.


TPI

Za účelom bližšieho charakterizovania reliéfu som popri relatívnom prevýšení zvolil premennú topografického pozičného indexu (Obr. 20). Premennú TPI možno do istej miery stotožniť s Lloberovou „Topographic Prominence“ (LLOBERA 2001, 1007) alebo v českej archeológii hojne používaným RIM indexom (DANIELISOVÁ 2008, 146; DRESLER - MACHÁČEK 2008, 175; GOLÁŇ 2001, 72). Pre tvorbu tejto premennej som použil súbor nástrojov Topographical Tools (JENNESS) pre ArcGIS. Základom tejto klasifikácie krajiny je Topographic Position Index, (WEISS 2001). Raster vzniká jednoduchým výpočtom rozdielu nadmorskej výšky a priemernej nadmorskej výšky okolia bunky (Obr. 17). V prípade mnou skúmaného územia som zvolil veľkosť susedstva 5 x 5 buniek, teda 24 najbližších buniek. Pre definovanie okolia buniek v priestorových analýzach, používam termín susedstvo ako ekvivalent k anglickému neighbourhood.



Obr. 17 – Model výpočtu vrstvy TPI (JENNESS a kol. 2010).


Positívne hodnoty v tomto indexe značia, že bunka leží oproti okoliu vyššie, zatiaľ čo negatívne indikujú stav kedy bunka nižšie ako zvolené okolie. Ako naznačuje nasledujúci obrázok (Obr. 18) pri výrazne pozitívnych hodnotách má bunka skôr tendenciu byť vrcholom, horským svahom či chrbtom. Zatiaľ čo pri negatívnych hodnotách je skôr údolím či jeho dnom. Hodnoty okolo nuly sú potom vlastné plochým oblastiam bez výraznejšej zmeny terénu.




Obr. 18 – Charakterizácia hodnôt TPI (JENNESS a kol. 2010).

Pôvodne som zamýšľal tento raster rozdeliť do tried podľa jeho hodnôt a hodnôt sklonu terénu. Novovzniknuté kategórie by niesli názvy tradične používaných morfológických útvarov (vrchol, rovina, chrbát, údolie atď.). V snahe vyhnúť sa kategorickým premenným som tento postup zamietol. Ako vidno na obrázku (Obr. 19) pri samotnom výpočte indexu je kladený dôraz na veľkosť susedstva. Pri menšom rádiuse vyniknú jednotlivé bunky zatiaľ čo väčšie susedstvo kladie dôraz na oblasti. Strácajú sa jednotlivé rozdiely medzi bunkami.

TPI Values at 3 Different Scales



Obr. 19 – Vplyv veľkosti susedstva na hodnotu TPI (JENNESS a kol. 2010).



Obr. 20 – Vrstva topografického pozičného indexu.

Vrstvy časových vzdialeností

Interakciu ľudských komunit s ich okolím riadila predovšetkým dostupnosť. Táto sa postupom času upravovala systémom kultúrnych zvykov a mocenských režimov, ktoré organizovali, regulovali či obmedzovali vžitú pohybovú vzorce (DANIELISOVÁ 2008, 133; LLOBERA 2000, 67). Časová vzdialenosť nám často napomáha rozpoznať vzťahy medzi jednotlivými komponentmi, alebo ich najbližším okolím. Zároveň môže rámcovo načrtnúť hranice zázemia jednotlivých komponentov. Základom týchto analýz je vrstva nákladov (nákladový povrch).

Jedná sa o akúsi cenu, ktorú stojí prechod z bodu A do bodu B. Táto cena môže byť vyjadrená v jednotkách energie (Kalorie/Joule), času alebo jednotkou predstavujúcou relatívnu náročnosť. V tejto práci je nákladový povrch odvodený zo svažitosti terénu pomocou vzorca (Výraz 3 – Vzorec pre výpočet vrstvy nákladového povrchu. Výraz 3) použitého v práci A. Danielisovej (2008) a doporučovaného tvorcami programu IDRISI (EASTMAN 2009c). Do analýz som nezaradil krajinné prvky, ako veľké vodné toky, neprechodné vodné toky či vegetáciu. Tieto prvky sú z veľkej časti nenávratne stratené a ich náročné rekonštruovanie je nad rámec spracovávanej témy.

$$Y = 0.031 * \sqrt{slope} - 0.025 * slope + 1$$

Výraz 3 – Vzorec pre výpočet vrstvy nákladového povrchu.


Aj napriek tomu môže vrstva poskytnúť aspoň rámcovú predstavu o vzdialenostiach medzi jednotlivými prvkami. V práci som použil dve vrstvy anisotropických časových vzdialeností: časovú vzdialenosť od nívnych sedimentov a časovú vzdialenosť archeologických komponent od hradísk. Výpočty oboch vrstiev som vykonal v programe IDRISI s použitím modulu VARCOST (DANIELISOVÁ 2008, ; GOLÁŇ 2001). Takto vzniknutá vrstva predstavuje relatívne vzdialenosti medzi počiatočným a koncovým bodom analýzy. Vynásobením tejto hodnoty veľkosťou bunky (0,03 km) a vydelením predpokladanou rýchlosťou chôdze (5km/h) vznikne vrstva časovej vzdialenosti.

Je pravdou že takýto prístup má veľa slabín. Nepočíta s množstvom faktorov, ktoré prechod krajinou ovplyvňujú, ako stav či prípadná existencia cesty, okolitá vegetácia, spôsob prepravy nákladu a jeho váha, kondícia cestovateľa či dokonca jeho výbava a výstroj. Jedným s často opomínaných faktorov pri rekonštrukcii samotných trás je aj jej dĺžka a z toho sa odvíjajúca rýchlosť, ktorou cestovateľ postupuje. Strmé klesanie nemusí


nutne predstavovať väčší problém pri jednorazovej ceste ale pri opakovaných vyčerpávajúcich cestách je potrebné pristupovať nanajvýš opatrne a vyhnúť sa napríklad dlhodobým následkom takých terénov (úrazy kolien atď.). Aj napriek týmto skutočnostiam je modelovanie časových vzdialenosti pre archeológa veľkou pomocou. Za pomoci týchto modelov sme schopní stanoviť akési limity v zmysle: „trvalo to aspoň takto dlho“ (TRIPCEVICH 2004).

TNIVA

Pre vrstvu časovej vzdialenosti od nivy (Obr. 21) som za východiskové body zvolil plochy v geologickej mape regiónu označené ako nivy riek či potokov. Tieto boli z vektorovej podoby mapy extrahované a prevedené do podoby rastra. Z nasledujúceho grafu (Graf 8) je zreteľné, že veľká časť buniek vo vrstve leží v tesnej blízkosti nivy. Tento stav je odrazom celkového rázu krajiny, kde väčšina kotlín je vyplnená nivnými sedimentmi.




Obr. 21 – Vrstva časovej vzdialenosti od nivných sedimentov.




Graf 8 – Odhad jadrovej hustoty pravdepodobnosti hodnôt vo vrstve TNIVA.

THRADISKA


Pre vrstvu časovej vzdialenosti od hradísk (Obr. 22) som za východiskové body zvolil výber z vrstvy včasno stredovekých komponentov, označených ako hradiská (). Bližšiu charakteristiku rozloženia hodnôt vo vrstve zobrazuje graf nižšie (Graf 9).



Obr. 22 – Vrstva časovej vzdialenosti od najbližšieho hradiska.



Graf 9 – Odhad jadrovej hustoty pravdepodobnosti hodnôt vo vrstve THRADISKA.



Obr. 23 – Hradiská v skúmanej oblasti. Popisok u bodu predstavuje hodnotu pola IdKomp zo súpisu hradísk (Tab. 53).

Vrstvy enviromentálných premenných

FLORA a SOIL

Vrstvy FLORA (Obr. 7) a SOIL (Obr. 3) boli v tejto fázy prevedené z pôvodnej vektorovej podoby na rastrovú. Každá z vrstiev sa skladala z buniek o veľkosti 30 x 30 metrov. Pomocou nástrojov Spatial Analysis (ESRI 2011) som spočítal plochy jednotlivých kategórií a údaje neskôr použil v teste chi-kvadrátu.

Štatistické analýzy a výpočty

Dôležitým krokom v druhej fáze modelu je overovanie platnosti čiastočných (parciálnych) hypotéz o vplyve premenných na výber vhodného miesta pre osídlenie.

Testy signifikancie

U každej z premenných som predpokladal, že ak by distribúcia archeologických areálov nebola ovplyvnená žiadnym faktorom obsiahnutým v uvažovaných premenných, ich rozmiestnenie by bolo náhodné. Hodnoty vzniknuté ovzorkovaním týchto premenných archeologickými bodmi (NEUSTUPNÝ 1986, 533) by spĺňali predpoklady náhodného výberu. Ich charakteristiky by sa nemali signifikantne odlišovať od charakteristík celej vrstvy. Tento predpoklad som použil ako nulovú hypotézu. Táto by platila iba v prípade, ak by hodnoty v archeologickej vrstve mali rovnaké rozdelenie ako hodnoty príslušnej vrstvy.

H_0 : Rozloženie súboru je náhodné.

H_a : Rozloženie súboru nie je náhodné.

Neplatnosť tejto nulovej hypotézy by logicky indikovala existenciu ovplyvňujúceho faktoru v rámci príslušnej premennej. Ide teda o otázku miery entropie. Aktivita človeka vytvára vlastnosti, ktorých výskyt je bez tejto aktivity nepravdepodobný. Komponenty by teda mali mať malú mieru entropie (NEUSTUPNÝ 2007, 30), teda mali by obsahovať určitý vzorec chovania v priestore.

Na overenie či sa rozdelenie mnou vybranej vzorky signifikantne odlišuje od rozdelenia celku (populácie) a hodnoty v nej obsiahnuté sú pre výber umiestnenia lokality významné, som postupoval podľa diagramu na obrázku vyššie (Obr. 5).

Chí-kvadrát

Pre kategorické (nominálne) premenné som použil testu chí-kvadrát. Test je bežne používa od jeho prvej aplikácie I. Hodderom a C. Ortonom v roku 1976 (VERHAGEN 2007, 46), test pomáha pri rozhodnutí či je rozloženie komponent v rámci kategórii odlišné oproti rozloženiu komponentov v kategóriách v prípade náhodného rozloženia. Test porovnáva počet pozorovaných (Obs. – z anglického observed) a očakávaných (Exp. – z anglického expected) výskytov v rámci každej kategórie. V našom prípade porovnáva, koľko komponent sa nachádza v danej kategórii oproti očakávaným počtom, vzhľadom na veľkosť kategórie.

Predpokladaný počet nálezísk v kategórii by mal mať také percentuálne zastúpenie v rámci všetkých lokalít, aké je percentuálne zastúpenie kategórie v rámci celku (DRENNAN 2010, 193). Pričom vychádza z očakávania, že rovnaké percento zastúpenia jednotlivých kategórii v celku majú aj náleziská v nich ležiace. Test stráca svoju silu pri malých súboroch a má známe limity. K obmedzeniam patrí neplatnosť výpočtu chí-kvadrátu ak nie sú všetky očakávané hodnoty početnosti väčšie ako 1 a ak aspoň 20% z očakávaných početností nie je väčších ako 5 (GRAPHPAD 2007d). Tento predpoklad však možno splniť spojením viacerých riadkov (kategórii). Z výsledku je teda možné odhadnúť signifikantnosť súboru a následne zaistiť, aby sa na vzniku modelu podieľali iba signifikantné premenné.

Testy normality

Pre testovanie premenných v ordinárnom formáte som sa rozhodol použiť testy zhody stredných hodnôt. Prostredníctvom týchto testov je možno zistiť či výbery pochádzajú z rovnakého rozdelenia pravdepodobnosti. (MELOUN - MILITKÝ 2002, 149). Pred použitím samotného testu je nutné získať predstavu o rozložení týchto súborov. Zistiť, či je možné u týchto premenných predpokladať normálne rozdelenie. Testy normality sú vhodné na podporu rozhodnutia pre výber parametrických či neparametrických testov v nasledujúcich analýzach. No samotné rozhodnutie by nemalo byť automatické len na základe výsledku testu, teda či môžeme u súboru predpokladať normálne rozloženie alebo naopak.

Testy normality sú vo všeobecnosti menej užitočné ako sa na prvý pohľad zdá. Overiť, či súbor pochádza z normálneho rozloženia, je pri malom počte vzoriek (hodnôt) veľmi zložité. Test nemá dostatok sily na odhalenie nenormálneho rozloženia. Naopak, pri veľkých súboroch vďaka robustnosti parametrických testov (ANOVA, t-test atď.) je overovanie normality zbytočne (GRAPHPAD 2007d). Ďalšiu slabinu predstavuje výskyt odľahlých a extrémnych hodnôt v testovanom súbore. Pomocou on-line kalkulatoru Grubbsova testu na určovanie odľahlých hodnôt (GRAPHPAD 2007b), alebo použitím boxplot grafu v programe STATISTICA je možné takéto hodnoty vypátrať. Pri interpretácii výsledku testu normality potom možno k ich existencii prihladiť alebo ich z testovaného súboru pred samotným testom odstrániť.

Nulová hypotéza u testu normality predpokladá, že rozloženie príslušného súboru je zhodné s normálnym rozložením. Pri teste sa vypočíta testovacia štatistika. Tu je možné interpretovať, ako mieru nekompatibility skúmaného súboru s nulovou hypotézou, či ako štatistickú vzdialenosť dát od nulovej hypotézy. V prípade, ak je rozloženie dát rovnaké s predpokladaným rozložením (nulová hypotéza), je hodnota testovacej štatistiky malá. Hodnota narastá v prípade odlišnej konfigurácie súborov (napr. v prípade rozdielnych hodnôt priemeru atď.). V prípade, ak je hodnota vzdialenosti väčšia ako kritická hodnota, získané dáta naznačujú neplatnosť nulovej hypotézy.

Testovaciu štatistiku môžeme tiež previesť na tzv. hladinu významnosti (p). Táto vyjadruje pravdepodobnosť, že získame vypočítanú hodnotu, pokiaľ platí nulová hypotéza. Teda ak je hodnota hladiny významnosti malá, je veľká pravdepodobnosť, že nulová hypotéza neplatí. V zásade platí: p -hodnota menšia, ako zvolená hladina alfa indikuje neplatnosť nulovej hypotézy. Hodnota p väčšia ako alfa ju ponecháva v naďalej platnosti a svedčí skôr o nedostatku evidencie k jej zamietnutiu (HENDL 2006, 177-178, 186). Hladinu alfa, predstavuje pravdepodobnosť, že zamietneme nulovú hypotézu, ktorá vo skutočnosti platí, teda tzv. chybu 1. rádu.

V rámci experimentu som použil tri testy normality ("Kolmogorov-Smirnov normality test", "D'Agostino & Pearson omnibus normality test", "Shapiro-Wilk normality test"), pričom ukázali odlišné výsledky. Hladinu významnosti (hladina alfa) som zvolil 5% (0,05). Táto výška hladiny bola rovnaká v priebehu všetkých testov uvedených v tejto práci.

Samotný Kolmogorov-Smirnovov test normality tvorcovia mnou použitého softwaru výslovne nedoporučujú, s odôvodnením, že výpočet hodnoty p prebieha len z jednej hodnoty: najväčšej diskrepancie medzi kumulatívnym rozdelením súboru a kumulatívnym normálnym rozdelením (GRAPHPAD 2007d). Nejedná sa tak o veľmi citlivé posúdenie

normality, a preto súhlasia s vyjadrením R. B. D'Agostina: "The Kolmogorov-Smirnov test is only a historical curiosity. It should never be used" (GRAPHPAD 2007d).

Shapiro-Wilkov test je za považovaný spoľahlivý len v prípade, že hodnoty vstupujúce do analýzy sú unikátne (GRAPHPAD 2007d). V prípade duplicitných hodnôt v súbore sú jeho výsledky nepresvedčivé. Táto skutočnosť mohla hrať významnú úlohu napríklad pri teste vrstvy časovej vzdialenosti od hradísk (THRADISKA). V tejto vrstve nie je pravdepodobné, že sa budú hodnoty opakovať. Vyplýva to z formátu vrstvy, kde pole nesúce túto informáciu má formát „float“, čo predstavuje presnosť na 6 desatinných miest (ESRI 1999-2010). Táto presnosť je výsledkom procesu interpolácií pri vznikaní rastru. V skutočnosti nie sme schopní odhadnúť časovú vzdialenosť v rádoch 0,004 sekundy. Avšak pravé táto prehnaná presnosť nám zabezpečí unikátnosť hodnôt v súbore. Iná situácia by nastala, ak by testovaný súbor obsahoval aj samotné hradiská alebo formát vrstvy by bol stanovený ako „integer“ (celé čísla). Stratili by sa tak jemné rozdiely medzi bunkami a hodnota ich časovej vzdialenosti k najbližšiemu hradisku, pri postupe výpočtu ktorý som zvolil by bola prirodzene nula. Výskyt duplicitných hodnôt by bolo tiež možné očakávať pri použití súboru obsahujúci multikultúrne, alebo viacnásobné komponenty. V mojom prípade súbor neobsahoval lokality s rovnakými geografickými koordinátami. Preto možno pri tejto vrstve považovať za použiteľný. Inak je tomu u vrstiev obsahujúcich duplicitné premenné. V prípade časovej vzdialenosti od nivných sedimentov u lokalít ležiacich priamo v priestore týchto náplav môžeme očakávať nulovú a teda v rámci súboru duplicitnú hodnotu. Aplikácia a samotný výsledok Shapiro-Wilkovho testu je u takej premennej zbytočná.

Ako univerzálny test s veľkou silou je doporučovaný D'Agostino-Pearsonov test normality. V prvej fáze spočíta mieru špicatosti a šikmosti, pomocou ktorej kvantifikuje rozdielnosť tvaru rozloženia od očakávaného normálneho rozloženia. V druhej fáze potom pre každú hodnotu spočíta vzdialenosť od hodnoty patriacej do tohto rozloženia (GRAPHPAD 2007d). Zo súčtu týchto rozdielov následne vypočíta p-hodnotu. Výsledkom toho testu som prikladal najväčšiu váhu.

Jednovzorkový t-test

Jednovzorkový t-test sa používa na testovanie nulovej hypotézy, ktorá tvrdí, že priemer testovaného súboru sa rovná zadanej konštante, respektíve sa výrazne neodlišuje. Ak je p - hodnota nižšia ako zvolená hladina štatistickej významnosti je možné nulovú hypotézu zamietnuť a prijať alternatívnu hypotézu. Ak je p - hodnota vyššia ako hladina

alfa je rozdiel medzi priemerom súboru a zadanou konštantou dielom vnútornej variability hodnôt v dôsledku náhodného výberu a rozdiel nemožno považovať za štatisticky významný. Avšak nemôžeme tvrdiť, že priemery sú rovné. Tento výsledok nám iba odhalí nedostatok dôkazov na vyvrátenie nulovej hypotézy (GRAPHPAD 2007d).

K získaniu konštanty (priemer) bolo potreba vypočítať základné charakteristiky vrstiev. K tomuto je v programe ArcGIS určený nástroj Zonal Statistics As Table (ESRI 1999-2010). Kde zónu predstavoval celý rozsah skúmanej oblasti.

Wilcoxonov znamienkový test

Na výpočet Wilcoxonoho znamienkového testu som použil program GraphPad (GRAPHPAD 2007a). Nulová hypotéza Wilcoxonova testu tvrdí, že medián skúmaného súboru sa rovná zadanej konštante. Ak je p - hodnota nižšia ako hladina významnosti alfa (0.05), je nulová hypotéza zamietnutá. Rozdiel medzi mediánmi je natoľko významný že nemôže byť spôsobený náhodným výberom. Naopak, ak je p - hodnota vyššia alebo rovná hodnote alfa je rozdiel štatisticky nevýznamný (HENDL 2006, 193).

Hodnoty konštanty pre každú vrstvu som podobne ako v prípade priemernej hodnoty (konštanty pre t-test) získal za pomoci programu ArcGIS. Program dokáže vypočítať hodnotu mediánu pre celú vrstvu iba v prípade, že je hodnota v bunkách uvedená vo formáte celých čísiel (integer). Vrstvy SLOPE a LR150 som teda pomocou nástroja single map algebra previedol do formátu celých čísiel (Výraz 4).

`=int(grid_name)`

`=int(grid_name * 1000)`

Výraz 4 – Výrazy použité na prevod vrstiev do formátu celých čísiel.

U vrstiev TPI a TNIVA som hodnoty v bunkách najprv vynásobil hodnotou 1000 a následne previedol do formátu „integer“. U posledne spomenutých by sa zaokrúhlením na celé čísla bez predchádzajúcej úpravy konštantou stratili cenné informácie nachádzajúce sa na mieste desatinných čísiel.

Mann-Whitneyho test

Tento test porovnáva rozdielnosť mediánov a slúži k zisteniu, či existuje významných rozdiel. Test odpovedá na otázku, či je rozdiel mediánov (presnejšie priemerov poradí) dvoch skupín štatisticky významný alebo iba náhodný (RIMARČÍK 2008). Nulová hypotéza predpokladá, že rozdelenie oboch súborov je totožné. Jej platnosť je možná iba v prípade, že p - hodnota je menšia ako 0,05. V opačnom prípade na prijatie hypotézy nie je dostatok evidencie a je prijatá alternatívna hypotéza o existencii rozdielu.

Pridelovanie váh v rámci premenných

Priebeh pridelovania váh bol vzhľadom na rozdielnosť formátov pre skupiny ordinárnych a nominálnych premenných odlišný.

Pre vrstvy v nominálnom formáte (FLORA, SOIL) som použil podiel pozorovaného počtu komponentov v jednotlivých kategóriách a ich predpokladaného⁷ (očakávaného) počtu (Výraz 5). Práve tento pomer umožňuje zistiť, ktoré kategórie (oblasti) najväčšou mierou ovplyvňujú distribúciu komponentov a ktorým je treba prideliť najväčšie váhy.

$$I_v = \frac{Obs}{Exp}$$

Výraz 5 – Vzorec pre výpočet Indexu významnosti, kde Obs je počet pozorovaných komponent a Exp značí počet očakávaných komponent v kategórii.

Tento kvocient zodpovedá indexu relatívnej intenzity osídlenia (JASIEWICZ - HILDEBRANDT-RADKE 2009, 2101) či indexu významnosti (KUNA 2008, 86). Vyjadruje mieru preferencie osídlenia v danej kategórii, teda koľko krát častejšie sa komponent nachádza v kategórii oproti očakávaniu. Ak sa hodnota indexu rovná 1, ide o kategóriu v ktorej je pozorovaný počet komponentov rovnaký s predpokladom. Komponenty sa v kategórii nekumulujú a ich rozdelenie je blízke rozdeleniu predpokladanému. Ak však aj

⁷ Výpočet predpokladaného počtu je popísaný v odstavci o teste chi-kvadrát na strane 54.

napriek nízkemu zastúpeniu kategórie v celku sa lokality v tejto kategórii objavujú nadpočetne, je index väčší ako 1 a teda možno považovať túto kategóriu za preferovanú pri výbere miesta k osídleniu. Podiel pozorovaných a očakávaných výskytov komponentov v kategóriách som previedol do škály reálnych čísiel kde 0,00 predstavuje najnižšiu hodnotu indexu významnosti a 1,00 maximálnu (Tab. 23). Pri výpočte som použil vzorec pre lineárnu interpoláciu z nástroja pre ArcGIS vytvoreného Ing. Vladimírom Zenklom z firmy Arcdata Praha (Výraz 6), (ZADEH 1965). Takto upravená hodnota indexu významnosti bude predstavovať váhu jednotlivých kategórii.

$$N = \frac{(X - X_{\min})}{X_{\max} - X_{\min}} * (N_{\max} - N_{\min}) + N_{\min}$$

Kde N je novo vypočítaná hodnota a X predstavuje stará pôvodnú hodnotu. Xmax a Xmin sú maximum a minimum v stĺpci pôvodných hodnôt. Nmax a Nmin potom maximum a minimum novej stupnice v našom prípade 1 a 0.

Výraz 6 – Vzorec pre lineárnu interpoláciu (ZENKL 2010).

Postup pridelenia váh v prípade spojitých premenných (SLOPE, LR150, TCI, TNIVA, THRADISKA) sa vzhľadom k povahe dát a snahe vyhnúť sa zbytočnej kategorizácii, líšil. Ako vhodný nástroj sa pre tento účel ukázal modul FUZZY v programe IDRISI. Tento modul sa riadi princípmi fuzzy logiky, ktorá je založená na teórii neostrých hrán (NOVÁK 2000, ; ROBINSON 2009, ; ŠMEJDA 2003, 233; ZADEH 1965). Fuzzy logika pracuje s takzvanými vágnymi množinami, ktoré lepšie zodpovedajú situáciám z reálneho sveta. Zatiaľ čo v logike ostrých hrán musí prvok v množine patriť alebo nepatriť, fuzzy logika určuje stupeň prináležitosti k tej či onej množine (ŠMEJDA 2003, 233).

Rozdielom oproti booleanovskej logike, kde je nutné dáta kategorizovať a jednotlivým kategóriám priradiť váhy, je v samotnom prístupe ku kategóriám. Princíp fuzzy logiky spočíva v neexistencii kategórii pri práci s FUZZY modelom sa váhy hodnotám nepridávajú striktné v rámci intervalov, ale kontinuálne narastajú či klesajú s ohľadom na priebeh použitej funkcie. Modul umožňuje použitie 3 štandardných funkcií, (funkcie tvaru S, J a funkcia s lineárnym priebehom). Pričom je možné zvoliť stúpajúcu, klesajúcu či kombináciou predošlých vytvoriť symetrickú funkciu (ŠMEJDA 2003, 236).

Pre stanovenie priebehu funkcie som použil histogram a funkciu odhadu jadrovej hustoty hodnôt v programe R. Porovnával som percentuálne zastúpenie komponent v jednotlivých intervaloch v rámci každej kategórie. Pričom kategórii s najvyšším percentom výskytu som priradil najvyššiu váhu. Výsledkom takéhoto procesu váženia, oblasti so zvýšeným výskytom komponent nadobúdajú vyšších váh ako oblasti bez alebo s menším počtom komponentov.

Pridelenie váh jednotlivým premenným

Pri posudzovaní vplyvu jednotlivých vrstiev som vychádzal z predpokladu, že váženie oblastí vo vrstvách pomocou FUZZY modulu bolo adekvátne a oprávnené „zvýhodnilo“ zóny s preferovanými vlastnosťami. K zaisteniu rôznej miery významnosti jednotlivých vrstiev (tvorba modelu M2⁸) som využil metódu podobnú ako pri tvorbe modelu v práci J. Jasiewicz a I. Hildebrandt-Radke (JASIEWICZ - HILDEBRANDT-RADKE 2009, 2109), tá je založená na priradení rozdielnych váh na základe počtu komponentov nachádzajúcich sa v intervale väčšom ako priemerná hodnota potenciálu plus smerodajná odchýlka. Vzhľadom na nesymetrické a nenormálne rozloženie väčšiny vrstiev (Tab. 13) som ako hraničnú hodnotu miesto spomínaného priemeru + štandardná odchýlka použil horný kvartil (Q3). Ten tvorí hranicu, pod ktorou sa nachádza 75% hodnôt v súbore. Podobné percento (83%) leží pod hranicou priemeru + smerodajnej odchýlky v prípade normálne rozloženého nesymetrického súboru. Týmto procesom získame predstavu o významnosti jednotlivých vrstiev, ktoré budú výsledný model tvoriť. Vysoké percento komponentov v oblastiach s vysokým potenciálom v rámci váženej vrstvy bude znamenať aj výslednú zvýšenú dôležitosť tejto vrstvy v procese tvorby modelu.

⁸ Viac na strane 94 v stati Otázka vplyvu odlišných váh.

	Priemer	Smer. Odchýlka	Šikmost ⁹	Špicatosť ¹⁰
WSLOPE	0.161	0.259	2.168	3.477
WTCI	0.822	0.229	-1.470	1.703
WLR150	0.293	0.336	0.880	-0.778
WTNIVA	0.345	0.365	0.799	-0.974
WTHRADISKA	0.484	0.442	0.047	-1.809

Tab. 13 – Základné popisné charakteristiky premenných v spojitom formáte.

Jednotlivé percentuálne podiely komponent (Tab. 14) v intervaloch som previedol pomocou vzorca (Výraz 7) do škály od 0,00 – 1,00. Vzorec som upravil, tak, aby bol využitý potenciál všetkých vrstiev. V pôvodnom vzorci pre lineárnu interpoláciu by počet komponentov v intervale väčšom ako horný kvartil u vrstvy WFLORA predstavoval minimum a vrstva by v procedúre MCE bola zbytočná, pretože jej výsledná váha by bola 0. Vo vzorci som teda umelo definoval hodnotu minima na 0. Po prepočte tak vrstva získala váhu síce minimálnu (0,53), ale nie nulovú.

$$N = \frac{X - 0}{X_{\max} - 0}$$

Výraz 7 – Upravený vzorec lineárnej interpolácie.

⁹ Šikmost' meria asymetriu dát. Hodnota 0 je priradená symetrickému rozdeleniu. Hodnoty väčšie ako 0 či menšie ako 0 potom značia vychýlenosť súboru na ľavo či na pravo.

¹⁰ Špicatosť meria odchýlku špicatosti od normálneho rozdelenia. Ploché krivky majú hodnotu väčšiu ako 0, špicaté zase menšiu ako 0.

NAME	počet	Q3	%	W_Q3
WSLOPE	33	0.16	71.74	0.92
WTCI	24	1.00	52.17	0.67
WLR150	36	0.59	78.26	1.00
WTNIVA	34	0.65	73.91	0.94
WTHRADISKA	24	1.00	52.17	0.67
WFLORA	19	0.59	41.30	0.53
WSOIL	26	0.08	56.52	0.72

Tab. 14 – Váhy jednotlivých premenných.

Z predchádzajúcej tabuľky (Tab. 14) sú zrejmé jednotlivé váhy, ktoré som použil pri výpočte Modelu 2 (W_Q3). Pole „Q3“ predstavuje hodnotu tretieho kvartilu príslušnej váženej vrstvy. Pole „počet“ obsahuje presný počet komponentov ležiacich v intervale väčšom ako hodnota tretieho kvartilu. V poli „%“ vidíme percentuálny podiel tohto počtu.

Analýza


Vytváranie modelov patrí k jedným zo základných postupov pri archeologickej interpretácii (NEUSTUPNÝ 2007, 176). Idea modelovania osídlenia vychádza z predpokladu, že rozmiestenie archeologických lokalít nie je náhodné. Očakávame teda, že za pozorovanou distribúciou lokalít možno hľadať určitý vzorec. Tento predpoklad sme však schopní potvrdiť iba v prípade správne zvolených premenných tvoriacich náš model. Práve v definovaní týchto závislostí je základný rozdiel medzi intuitívnymi modelmi, vnímajúcimi tieto charakteristiky poučenou intuíciou a objektívnymi modelmi, ktoré ich exaktne popisujú a snažia sa ich kvalifikovať a kvantifikovať, istým spôsobom zmerať. V mojej práci som sa snažil uplatniť práve druhý spôsob.

Pri tvorbe modelu dominovala predstava, že výber lokality je vo veľkej miere ovplyvnený praktickými požiadavkami na polohu. Tento predpoklad vychádzal jednak z nedostatku informácií o vývoji osídlenia v regióne a jednak z časovej náročnosti modelovania iných ako racionálnych podmienok.

Pri modelovaní predpokladáme, že krajina predstavuje kontinuálne osídlenú plochu (populácia); (NEUSTUPNÝ 2006, 89). Z výskumov poznáme iba časť osídlenia. Tento výrez ľudských aktivít môžeme považovať za vzorku vhodnú k analýze osídlenia. Jednotkou takejto vzorky je komponent. Charakteristiky populácie však nie sme nikdy schopní postihnúť a ich hodnoty iba odhadujeme. Charakteristiky vzorky do značnej miery závisia od vlastností jednotlivých komponentov. Preto, aby bol náš odhad čo najpresnejší, musí byť táto vzorka dostatočne kompaktná, teda musí mať spoločného menovateľa. Tento by mal byť čo najvyšší. Vzorka musí byť reprezentatívnym výberom fenoménu, ktorý sa snažíme predikovať (VERHAGEN 2009). Pomocou mnou zvolenej metódy nie je možné predikovať z pohrebísk sídliská. Tieto predstavujú iný typ komponentu, prejavujúci sa teréne inými príznakmi a majúci iné charakteristiky. Problémom je v tomto prípade aj tzv. „objaviteľnosť“ komponentov (NEUSTUPNÝ 2007, 65). Existuje celý rad činností, ktoré nezanechávajú žiadne pozostatky, na základe ktorých by sme boli schopní identifikovať kde sa odohrali. Preto nie je možné tieto aktivity týmto spôsobom priamo predikovať.

Tvorba DESIGN a TEST SAMPLE

S ohľadom na hlavný zdroj archeologických dát (Tab. 8); (povrchový zber), zvolenú metódu práce a skutočnosť, že je model zostavovaný prevažne z environmentálnych premenných, bolo možné predikovať iba komponenty identifikovateľné povrchovým zberom. Predpokladám, že medzi takéto patria komponenty so sídelnou aktivitou. U takéhoto súboru je možno predpokladať rovnakú mieru pozorovateľnosti v krajine (NEUSTUPNÝ 2007, 176). Odstránením komponentov s pohrebnou aktivitou (26) a komponentov s centrálnym charakterom (14) som získal súbor 91 komponent (Tab. 52; Obr. 24). V tomto súbore sa spolu so sídelnými komponentmi nachádzajú aj komponenty označené heslom „INE“. Pod tento termín som zaradil komponenty s nejasným určením funkcie, ojedinelé nálezy a nálezy označené ako depot. Primárne som predpokladal, že tieto aktivity súvisia so sídelnými aktivitami blízkych komponentov, či už známych alebo doposiaľ neobjavených.



Obr. 24 – Vrstva sídliskových archeologických komponentov.

Distribúciu sídelných komponentov v krajine považujem za viac ovplyvnenú racionálnymi faktormi, ako komponentov pohrebného charakteru a komponenty označenej ako hradisko. Výber miesta pre pohrebisko ako aj pre areál centrálného charakteru sa nutne riadil inými požiadavkami ako výber miesta pre sídlisko. U týchto predpokladám väčšie ovplyvnenie iracionálnymi faktormi, ktoré je možno, ak vôbec, rekonštruovať veľmi ťažko.

Všetky komponenty (Tab. 52) vyhovujúce vyššie spomenutým kritériám som pre jednoduchšiu identifikáciu označil v poli MODEL hodnotou 1.


Súbor som za pomoci nástroja Hawth tools (BEYER 2004) náhodným výberom rozdelil na dva počtom približne rovnaké podsúbory. Súbor 46 komponent som použil na tvorbu modelu (DESIGN SAMPLE¹¹) zvyšných 45 komponent tvorilo testovaciu vzorku (TEST SAMPLE¹²); (VERHAGEN 2007, 136-137). Aj toto rozdelenie som zaznamenal do tabuľky v poli RNDSEL (pre záznamy tvoriace testovaciu vzorku hodnotou 0, pre záznamy podieľajúce sa na tvorbe modelu hodnotou 1). V tabuľke (Tab. 15) sú prehľadne zobrazené počty jednotlivých komponentov. Rozdelením vrstvy archeologických komponent som vytvoril na modely nezávislý súbor pomocou ktorého bude možno otestovať predpoklady uplatnené pri tvorbe modelu.

MODEL	TEST	DESIGN	Celkom
0	40	0	40
1	45	46	91
Celkom	86	46	131


Tab. 15 - Prehľad počtu komponentov v jednotlivých výberoch.

¹¹ Obr. 25 – Distribúcia komponentov patriacich do DESIGN SAMPLE. Popisok v mape predstavuje hodnotu pola IdKomp z tabuľky 52.

¹² Obr. 26 – Distribúcia komponentov patriacich do TEST SAMPLE. Popisok v mape predstavuje hodnotu pola IdKomp z tabuľky 52.



Obr. 25 – Distribúcia komponentov patriacich do DESIGN SAMPLE.



Obr. 26 – Distribúcia komponentov patriacich do TEST SAMPLE.

Testy signifikancie

Základným predpokladom pri modelovaní bolo, že výber miesta vhodného pre osídlenie podliehal istým zákonitostiam (DANIELISOVÁ 2008, 123). Túto teóriu som sa rozhodol otestovať za pomoci testov významnosti. Tie môžu napomôcť pri rozhodnutí, či atraktivita určitých oblastí je výsledkom skutočnej preferencie týchto zón, alebo je iba odrazom celkového rázu krajiny.

Vrstvy premenných v kategorickom (nominálnom) formáte

Pre vrstvy FLORA a SOIL som použil test chi-kvadrát. Vrstva potenciálnej vegetácie (FLORA) bola s ohľadom na požiadavky chi-kvadrát testu reklasifikovaná. Aby som odstránil kategórie, ktoré neobsahovali dostatočný počet komponentov a nemohli samostatne figurovať v teste, zúžil som počet vrstiev z pôvodných 28 na 4.

- Do kategórie bukové lesy som zaradil: Bukové (F) a jedľové (A) lesy kvetnaté, Bukové kvetnaté lesy podhorské, Bukové kyslomilné lesy horské, Bukové kyslomilné lesy podhorské, Bukové lesy vápnomilné, Bukovo-borovicové lesy a ostrevkové spoločenstva.
- Kategória dubové lesy obsahuje: Dubové kyslomilné lesy, Dubové nátržníkové lesy, Dubové subxerothermofilné a borovicové xerofilné lesy, Dubové xerothermofilné lesy submediteránne a skalné stepi, Dubovo-cerové lesy, Dubovo-hrabové lesy karpatské, Dubovo-hrabové lesy lipové, Dubovo-hrabové lesy panónske.
- Kategória lužné lesy obsahuje: Lužné lesy podhorské a horské, Lužné lesy nížinné a Lužné lesy vrbovo-topolové
- Do poslednej kategórie som zaradil ostatné typy vegetácie bez zastúpenia komponentov. Sú to: Borovicové kyslomilné lesy a trávnaté porasty viatych pieskov, Javorové horské lesy, Jedľové a jedľovo-smrekové lesy, Lipovo-javorové lesy, Slatiniská, Smrekové lesy čučoriedkové, Smrekové lesy vysokobylinné, Smrekové lesy zamokrené, Smrekovo-borovicové lesy a ostrevkové spoločenstvá, Subalpínske kosodrevinové a trávinné kyslomilné spoločenstvá, Subalpínske kosodrevinové a trávinné vápnomilné spoločenstvá.

V oblasti prevažujúca skupina bukových lesov s percentuálnym zastúpením 57% a 7%-tným zastúpením komponentov, sa ukázala ako takmer nevýznamná. Naproti tomu skupina lužných lesov so slabým percentuálnym zastúpením v rámci vrstvy potenciálnej vegetácie, iba 12%, je obsadená 41% komponentov. Čo je z pomedzi všetkých kategórii najviac a preto aj index významnosti (Tab. 16) je v tejto kategórii najvyšší.

FLORA								O/E
Info	Počet buniek	Plocha (km2)	Plocha (%)	Obs.	Exp.	O-E	x2	Index významnosti
Bukové lesy	5487178	4938	57	3	26.43	-23.43	20.77	0.11
Dubové lesy	2491927	2243	26	24	12	12	11.99	2
Lužné lesy	1158781	1043	12	19	5.58	13.42	32.26	3.4
ostatné	412540	371	4	0	1.99	-1.99	1.987	0
	9550426	8595	100	46			67.01	

Chi-Square = 67.0107 df = 3 p = .000000

Tab. 16 – Výsledky testu chí-kvadrát vrstvy FLORA.

Vrstva pedologických typov predstavuje 30 pôdných kategórii v oblasti. Aj túto bolo v rámci dodržania predpokladov na správny výpočet testu chí-kvadrátu reklasifikovať. Tak ako v prípade vrstvy potenciálnej vegetácie (FLORA), som jednotlivé kategórie zvolil tak, aby každá skupina, ktorá obsahuje archeologický komponent, vstupovala do testu samostatne a neprenášala svoju významnosť na iné, menej významné kategórie.

SOIL								O/E
Info	Počet buniek	Plocha (km2)	Plocha %	Obs.	Exp.	O-E	x2	Index významnosti
ostatné	551321	496	5.77	0	2.66	-2.66	2.66	0
černozeme	69454	63	0.73	3	0.33	2.67	21.24	8.97
fluvizeme	599018	539	6.27	16	2.89	13.11	59.61	5.55
kambizeme	5107238	4597	53.48	11	24.6	-13.6	7.52	0.45
pseudogleje	473521	426	4.96	7	2.28	4.72	9.76	3.07
redziny	2749250	2474	28.79	9	13.24	-4.24	1.36	0.68
	9549802	8595	100	46	46		102.14	

Chi-Square = 102.1429 df = 5 p = 0.000000


Tab. 17 – Výsledky testu chí-kvadrát vrstvy SOIL.

Ako skupina s najväčšou váhou sa ukázala trieda černoziemí. Táto ojedinelá enkláva v turčianskej kotline predstavuje necelé 1 % pôd na skúmanom území. Aj napriek tomu som náhodným výberom zahrnul 3 archeologické komponenty ležiace v nej. Vysoký index významnosti prináleží aj skupine tzv. fluvizemí. Čo spolu s výsledkom testu chi-kvadrát u potenciálnej vegetácie svedčí o atraktivite územia, kde skupiny fluvizemí a lužných lesov čiastočne prekrývajú (Tab. 17).


U oboch vrstiev (FLORA, SOIL) výsledky chi-kvadrát testu potvrdili signifikantne odlišné rozloženie komponentov od očakávaných hodnôt na hladine významnosti 0.05.

Vrstvy so spojenými (ordinálnymi) premennými


U vrstiev v spojitom formáte bolo možno použiť testy porovnávajúce stredné hodnoty. Pred testovaním signifikancie som u každej z vrstiev som testoval jej predpokladané rozloženie. Ako normálne rozložené sa ukázali vrstvy orientácii na svetové strany (ASPECT) a vrstvy predstavujúce hodnoty topografického indexu vlhkosti (TCI). U týchto je možné predpokladať normálne rozloženie súboru pri hladine významnosti 0,05. V prípade vrstvy časovej vzdialenosti od hradísk (THRADISKA), rozhodnutie o normalite rozloženia za použitia "Shapiro-Wilk normality test" uniklo len o vlások.




Graf 10 – Krabicový graf hodnôt časovej vzdialenosti od nív v súbore DESIGN SAMPLE.



Graf 11 – Krabicový graf hodnôt topografického pozičného indexu súboru DESIGN SAMPLE.



Graf 12 – Krabicový graf hodnôt svažitosti súboru DESIGN SAMPLE.



Graf 13 – Krabicový graf hodnôt relatívneho reliéfu súboru DESIGN SAMPLE.

Ako jeden z dôvodov neúspešného testovania normality je často uvádzaný výskyt odľahlých a extrémnych hodnôt. U vrstiev, u ktorých možno predpokladať normálne rozloženie, sa odľahlé hodnoty nevyskytujú, zatiaľ čo u premenných (SLOPE, LR150, TPI a TNIVA), ktoré predpoklad normality nepotvrdili, je výskyt signifikantne odľahlých hodnôt badateľný (Graf 10 až Graf 13).

Zjednodušená tabuľka pod textom (Tab. 18) zobrazuje prehľadne výsledky testov normality. V nasledujúcej tabuľke (Tab. 19) sú zobrazené detailné informácie o výsledkoch.

	SLOPE	ASPECT	LR150	TPI	TCI	TNIVA	THRADISKA
Kolmogorov-Smirnov	No	Yes	No	No	Yes	No	Yes
D'Agostino & Pearson test	No	Yes	No	No	Yes	No	Yes
Shapiro-Wilk test	No	Yes	No	No	Yes	No	No

Tab. 18 – Prehľadné výsledky testov normality.

	SLOPE	ASPECT	LR150	TPI	TCI	TNIVA	THRADISKA
Number of values	46	46	46	46	46	46	46
Minimum	0.2942	15.52	2.12	-4.21	1.444	0	0.1625
25% Percentile	1.645	61.2	7.67	-0.8056	3.653	0	1.079
Median	3.25	95.26	20.74	-0.0696	4.76	0.0145	1.991
75% Percentile	7.822	117.8	37.26	0.3108	5.608	0.08277	2.979
Maximum	31.86	174.8	123.8	6.128	7.522	0.6132	5.36
Mean	5.813	91.39	28.63	-0.0009	4.614	0.08051	2.165
Std. Deviation	6.775	40.14	29.32	1.611	1.434	0.1535	1.392
Std. Error	0.9989	5.918	4.324	0.2376	0.2114	0.02264	0.2052
Lower 95% CI of mean	3.801	79.47	19.92	-0.4794	4.188	0.03491	1.752
Upper 95% CI of mean	7.825	103.3	37.34	0.4776	5.039	0.1261	2.578
KS normality test							
KS distance	0.2318	0.07546	0.183	0.2367	0.06861	0.3134	0.1211
P value	P<0.0001	P > 0.10	0.0005	P<0.0001	P > 0.10	P<0.0001	0.0885
Passed normality test?	No	Yes	No	No	Yes	No	Yes
P value summary	***	ns	***	***	ns	***	ns
D'Agostino & Pearson							
K2	31.08	0.9239	24.31	20.62	0.8847	34.26	3.206
P value	P<0.0001	0.63	P<0.0001	P<0.0001	0.6425	P<0.0001	0.2013
Passed normality test?	No	Yes	No	No	Yes	No	Yes
P value summary	***	ns	***	***	ns	***	ns
Shapiro-Wilk							
W	0.7444	0.9818	0.7865	0.8633	0.9853	0.5805	0.9492
P value	P<0.0001	0.6798	P<0.0001	P<0.0001	0.8236	P<0.0001	0.0438
Passed normality test?	No	Yes	No	No	Yes	No	No
P value summary	***	ns	***	***	ns	***	*
Sum	267.4	4204	1317	-0.04	212.2	3.703	99.59

Tab. 19 – Výsledky testov normality.

U vrstiev, u ktorých možno predpokladať normálne rozloženie (ASPECT, TCI, THRADISKA), som aplikoval jednovzorkový t-test.

Vrstvy s premennými, ktoré tento predpoklad na hladine alfa (0,05) nespĺnili (SLOPE, LR150, TPI a TNIVA), som z hľadiska signifikantnosti výberu testoval neparametrickým ekvivalentom jednovzorkového t-testu, Wilcoxonovým test (KVAMME 1990).

Výsledky t-testu prehľadne zobrazuje tabuľka pod textom (Tab. 20). U vrstvy časovej vzdialenosti od najbližšieho hradiska (THRADISKA) môžeme hovoriť o signifikantnom rozdiely v hodnotách priemerov. Podľa intervalu spoľahlivosti odhadu priemeru vieme, že na 95% sa hodnota priemeru nami testovaného súboru nachádza v intervale medzi 1,752 až 2.578 hodiny. Vzhľadom ku skutočnému priemeru vrstvy 4.942 je pravdepodobné, že súbor je štatisticky významný a môžeme predpokladať, existujúci vzťah medzi rozložením komponent a ich časovou vzdialenosťou od najbližšieho hradiska. Aj hodnoty topografického indexu vlhkosti (TCI) u skúmaného súboru prejavujú na základe výsledku

t-testu signifikantnú odlišnosť od celku. Priemernú hodnotu predstavuje hodnota 3.314. Táto leží mimo intervalu 4.188 až 4.614, predstavujúceho s 95% pravdepodobnosťou priemernú hodnotu vrstvy, reprezentovanú hodnotami našej vzorky.

Vrstva ASPECT sa ako signifikantá neprejavila. Jej intervalový odhad priemeru obsahuje aj hodnotu priemeru celej vrstvy orientácií najstrmšie klesajúcich svahov.

	ASPECT	TCI	THRADISKA
Number of values	46	46	46
Minimum	15.52	1.444	0.1625
25% Percentile	61.2	3.653	1.079
Median	95.26	4.76	1.991
75% Percentile	117.8	5.608	2.979
Maximum	174.8	7.522	5.36
Mean	91.39	4.614	2.165
Std. Deviation	40.14	1.434	1.392
Std. Error	5.918	0.2114	0.2052
Lower 95% CI¹³ of mean	79.47	4.188	1.752
Upper 95% CI of mean	103.3	5.039	2.578
One sample t test			
Theoretical mean¹⁴	87.85	3.314	4.942
Actual mean	91.39	4.614	2.165
Discrepancy	-3.544	-1.299	2.777
95% CI of discrepancy	-8.385 to 15.47	0.8731 to 1.725	-3.190 to -2.363
t, df	t=0.5989 df=45	t=6.145 df=45	t=13.53 df=45
P value (two tailed)	0.5522	P<0.0001	P<0.0001
Significant (alpha=0.05)?	No	Yes	Yes

Tab. 20 – Výsledky jednovzorkového t-testu.

¹³ CI je skratka z anglického Confidence interval, interval spoľahlivosti odhadu.

¹⁴ Theoretical mean označuje priemer populácie - v našom prípade celej vrstvy. Je to zároveň testovacia konštanta.

Pre súbory, ktoré neprešli testom normality a rozloženie ich hodnôt je iné ako normálne, som bol nútený zvoliť Wilcoxonov znamienkový test (Tab. 21).

	intSlope	intLR150	TPIx1000	TNIVAx1000
Number of values	46	46	46	46
Minimum	0	2	-4210	0
25% Percentile	1.75	8	-806	0
Median	3	21	-69.5	14.5
75% Percentile	8	37.25	310.8	82.75
Maximum	32	124	6128	613
10% Percentile	0.7	3.7	-1765	0
90% Percentile	17.3	70.1	2221	365
Mean	5.761	28.63	-0.8696	80.48
Std. Deviation	6.799	29.29	1611	153.5
Std. Error	1.003	4.319	237.6	22.64
Lower 95% CI of mean	3.742	19.93	-479.4	34.89
Upper 95% CI of mean	7.78	37.33	477.6	126.1
Wilcoxon Signed Rank Test				
Theoretical median¹⁵	13	67	-19	229
Actual median	3	21	-69.5	14.5
Discrepancy	10	46	50.5	214.5
Sum of signed ranks (W)	-892	-937	-137	-783
Sum of positive ranks	94.5	72	472	149
Sum of negative ranks	-986.5	-1009	-609	-932
P value (two tailed)	P<0.0001	P<0.0001	0.4575	P<0.0001
Exact or estimate?	Gaussian Approx.	Gaussian Approx.	Gaussian Approx.	Gaussian Approx.
Significant (alpha=0.05)?	Yes	Yes	No	Yes
Coefficient of variation	118.03%	102.32%	185302.63%	190.76%
Skewness	2.092	1.805	1.204	2.342
Kurtosis	4.632	3.074	4.767	4.566
Sum	265	1317	-40	3702

Tab. 21 – Výsledky Wilcoxonovho znamienkového testu.

¹⁵ Theoretical median je medián populácie - v našom prípade celej vrstvy. Je to zároveň testovacia konštanta.

Okrem mediánu hodnôt topografického pozičného indexu sa všetky ostatné ukázali ako signifikantne odlišné od testovanej konštanty.

Vzťah medzi komponentmi a enviromentálnymi premennými, ktorý môžeme z týchto hodnôt odpozorovať, nie je založený na náhode ale zodpovedá skutočnej preferencii istých oblastí. Hodnoty s 95% pravdepodobnosťou predstavujú iné ako náhodné či očakávané rozdelenie.

Za účelom experimentu som ďalej otestoval prostredníctvom t-testu aj premenné, ktoré neprešli testom na normalitu. Výsledok týchto t-testov (Tab. 22) iba potvrdil rozhodnutie o nezaradení vrstvy TPI do ďalšej fáze procesu tvorby modelu. Testovať premenné, ktoré úspešne prešli testom normality (ASPECT, TPI, THRADISKA) Wilcoxonovým znamienkovým testom som pokladal za zbytočné. Pri takomto počte prvkov by neparametrický test nevykazoval dostatočnú robustnosť.

	SLOPE	LR150	TPI	TNIVA
Number of values	46	46	46	46
Minimum	0.2942	2.12	-4.21	0
25% Percentile	1.645	7.67	-0.8056	0
Median	3.25	20.74	-0.0696	0.0145
75% Percentile	7.822	37.26	0.3108	0.08277
Maximum	31.86	123.8	6.128	0.6132
Mean	5.813	28.63	-0.0008697	0.08051
Std. Deviation	6.775	29.32	1.611	0.1535
Std. Error	0.9989	4.324	0.2376	0.02264
Lower 95% CI of mean	3.801	19.92	-0.4794	0.03491
Upper 95% CI of mean	7.825	37.34	0.4776	0.1261
One sample t test				
Theoretical mean	14.15	71.67	-0.002024	0.3217
Actual mean	5.813	28.63	-0.0008697	0.08051
Discrepancy	8.337	43.04	-0.001154	0.2412
95% CI of discrepancy	-10.35 to - 6.324	-51.75 to - 34.32	-0.4777 to 0.4801	-0.2869 to - 0.1956
t, df	t=8.346 df=45	t=9.954 df=45	t=0.004857 df=45	t=10.66 df=45
P value (two tailed)	P<0.0001	P<0.0001	0.9961	P<0.0001
Significant (alpha=0.05)?	Yes	Yes	No	Yes
Coefficient of variation	116.55%	102.41%	185284.80%	190.71%
Skewness	2.083	1.801	1.204	2.342
Kurtosis	4.536	3.057	4.767	4.565
Sum	267.4	1317	-0.04	3.703

Tab. 22 – Výsledky jednovzorkového t-testu.

Odmietnutím nulovej hypotézy o náhodnom rozmiestnení lokalít v krajine som získal sériu vrstiev obsahujúcich faktory, ktoré s najväčšou pravdepodobnosťou vplývali na rozloženie areálov. V snahe zachytiť tieto faktory som podrobil vrstvy procesu váženía.

Pridelenie váh v rámci premenných


Pri tvorbe modelu som ďalej pracoval iba s premennými, ktoré sa ukázali ako signifikantné. Pridelením rozdielnych váh kategóriám či intervalom v premenných, som sa snažil pretransformovať teóriu o preferencii týchto oblastí pri výbere miesta vhodného pre osídlenie do rastrovej podoby.

Vrstvy nominálnych premenných


Pri nominálnych premenných (FLORA, SOIL) som v teste chi-kvadrát vypočítal predpokladaný počet komponentov v jednotlivých kategóriách. Pomer medzi pozorovaným počtom výskytu nálezísk a ich očakávaným počtom umožňuje odhadnúť, do akej miery je táto kategória významná pre výber polohy. Prepočítaním hodnoty tohto indexu do škály 0 – 1 (Tab. 23) a priradení hodnôt k príslušným oblastiam, som takto vzniknuté vrstvy (WFLORA, WSOIL) použil pri tvorbe modelu (Obr. 27, Obr. 28).

WFLORA		WSOIL	
Info	Weight	Info	Weight
Bukové lesy	0.033344175	ostatne	0
Dubové lesy	0.587386135	cernice	1
Lužné lesy	1	fluvizeme	0.618380972
ostatné	0	kambizeme	0.049863481
		pseudogleje	0.342243181
		redziny	0.07578867

Tab. 23 – Váhy jednotlivých kategórii v premenných FLORA a SOIL.



Obr. 27 – Vrstva potenciálnej prirodzenej vegetácie po pridelení váh.



Obr. 28 – Vrstva pôdných typov po pridelení váh.


Vrstvy ordinárnych premenných

Aj u premenným v ordinárnom formáte som k rozdeleniu váh v rámci premennej pristúpil iba u vrstiev, ktoré sa ukázali ako významné. Prostredníctvom modulu FUZZY v programe IDRISI som priradil váhy jednotlivým intervalom na základe ich predpokladaného vplyvu na sídelnú štruktúru.


K samotnej definícii fuzzy množín je možno pristupovať podobne ako v prípade určovania váh pre kategórie v binárnych vrstvách (DRESLER - MACHÁČEK 2008, 135; GOLÁŇ 2001, 91). Je možno použiť určitého platného predpokladu o významnosti vplyvu danej charakteristiky na distribúciu komponentov, alebo postupovať podľa vypočítaných hodnôt určujúcich základné charakteristiky súboru a množín. V práci som využil prevažne druhého spôsobu. Jedná sa o vcelku subjektívny prístup k posúdeniu miery významnosti výskytu jednotlivých komponentov, a preto som sa snažil pristupovať nanajvýš zodpovedne a systematicky na základe formalizovaných metód.

SLOPE

Pre svažitosti (SLOPE) sú z histogramu (Graf 14) ako aj z grafu odhadu hustoty (Graf 15) zjavné základné charakteristiky priebehu funkcie použiteľnej vo FUZZY module.




Graf 14 – Histogram hodnôt v poli SLOPE.



Graf 15 – Odhad jadrovej hustoty pravdepodobnosti pre hodnoty v poli SLOPE.


Prudké klesanie počtu pozorovaných komponentov s rastúcou strmostou svahu, ma viedlo k použitiu funkcie tvaru J. Predpokladám, že najväčšiu atraktivitu majú polohy s bez výraznej svažitosti. Hodnote 0° bola pridelená maximálna významnosť 1. Plochy s klesaním svahu od 0° do 3° získali hodnoty významnosti od 1 do 0,5. Miestam s väčšou mierou klesania svahu bola pridelená miera významnosti od 0,5 do 0. Pridelenie polovičnej hodnoty potenciálu (0,5) nízkej hodnote svažitosti (3°), vychádza z hodnôt získaných z deskriptívnych údajov o rozložení hodnôt v súbore. Zatiaľ čo pod hranicou priemernej hodnoty súboru (aritmetický priemer = 5) leží 66% súboru, pod hranicou hodnoty mediánu leží 50%. V dôsledku nenormálneho rozloženia súboru, jeho značnej nesymetrickosti a špicatosti (Tab. 13) hodnota mediánu predstavuje pri súbore hodnôt z vrstvy SLOPE oveľa reprezentatívnejšiu charakteristiku ako hodnota aritmetického priemeru (HENDL 2006, 95).




Obr. 29 – Vrstva svažitosti po pridelení váh.

LR150

U premennej lokálneho prevýšenia v kruhu 150m bolo nutné vzhľadom na komplikované rozloženie hodnôt (Graf 16) použiť špeciálne definovanú funkciu. Jej číselné hodnoty uvedené v tabuľke (Tab. 24) tvoria zdrojové dáta pre graf (Graf 17) zobrazujúci jej priebeh.



Graf 16 – Histogram pre hodnoty v poli LR150.




Graf 17 - Odhad jadrovej hustoty pravdepodobnosti pre hodnoty v poli LR150.


Pre užívateľsky definovanú funkciu som sa rozhodol hlavne vďaka výskytu komponentov s prevýšením od 90-130m. Pri použití niektorej z prednastavených funkcií by význam týchto komponentov mohol úplne zaniknúť. Jedná sa o dva sídliskové komponenty a jeden ojedinelý nález a depot. Užívateľskú funkciu definujeme pomocou bodov jej priebehu. V rámci týchto bodov má potom funkcia lineárny priebeh. V module nie je možné definovať funkciu ako kombináciu S, J funkcií, ktorej priebeh by bol pre popis rozloženia komponentov vhodnejší. Body priebehu funkcie som vytvoril na základe percentuálneho zastúpenia komponentov v kategóriách definovaných tak, aby reprezentovali rozdelenie hodnôt v súbore (Tab. 24). Za účelom zachovania rovnakého rozpätia váh som percentuálne podiely interpoloval pomocou výrazu (Výraz 6) do intervalu hodnôt medzi 0.00 až 1.

od	do	počet	%	váha
0	9	13	28	1
9	22	11	24	0.85
22	36	9	20	0.69
36	49	7	15	0.54
49	63	2	4	0.15
63	77	0	0	0
77	90	0	0	0
90	104	1	2	0.08
104	117	2	4	0.15
117	131	1	2	0.08

Tab. 24 – Hodnoty definujúce priebeh užívateľskej funkcie pre vrstvu LR150.




Obr. 30 – Priebeh užívateľsky definovanej funkcie pre pridelenie váh vrstve LR150.




Obr. 31 – Vrstva relatívneho prevýšenia v kruhu 150m po pridelení váh.

TCI


Pri vážení topografického indexu vlhkosti (TCI) bolo možné použiť symetrickú sigmoidnú funkciu tvaru S. Z histogramu (Graf 18) ako aj grafu odhadu hustoty (Graf 19) vyplýva, že komponenty preferujú polohy s hodnotami TCI od 3,5 do 5,5. Preferujú tak pozície bez výraznejšieho zamokrenia. Hodnote 0 bola pridelená najnižšia váha, v intervale 0 až 3,5 miera váhy prostredníctvom funkcie tvaru S stúpa až po hodnotu jej maxima (1). Túto váhu majú hodnoty v celom intervale 3,5 až 5,5 za touto hranicou miera váhy klesá až na minimálnu úroveň (0); (Obr. 32).



Graf 18 – Histogram pre hodnoty v poli TCI.




Graf 19 - Odhad jadrovej hustoty pravdepodobnosti pre hodnoty v poli TCI.




Obr. 32 – Vrstva potenciálneho zamokrenia oblasti po pridelení váh.

TNIVA


Váhy časovej vzdialenosti od nívnych sedimentov najlepšie charakterizuje priebeh jednostranno klesajúcej funkcie tvaru J. Najväčšiu váhu som priradil vzdialenosti 0 hodín od hranice nivy. Teda v bezprostrednej blízkosti. Hodnota 0,1 hodiny potom dostala váhu polovičnú (Graf 20 a Graf 21; Obr. 33).



Graf 20 – Histogram pre hodnoty v poli TNIVA.




Graf 21 – Odhad jadrovej hustoty pre hodnoty v poli TNIVA.




Obr. 33 – Vrstva časovej vzdialenosti od nívnych sedimentov po pridelení váh.

THRADISKA

Premenná časovej vzdialenosti od hradísk v oblasti získala svoje váhové indexy použitím symetrickej sigmoidnej funkcie s kontrolnými bodmi 0, 1, 3 a 6. Podľa histogramu (Graf 22) a odhadu jadrovej hustoty premennej (Graf 23), je zreteľne vidieť, že najväčšie percento komponentov sa nachádza vo vzdialenosti 1 až 3 hodín chôdze od najbližšieho hradiska (Obr. 34).



Graf 22 – Histogram pre hodnoty v poli THRADISKA.




Graf 23 – Odhad jadrovej hustoty pre hodnoty v poli THRADISKA.

Prehľadné zobrazenie typov funkcií a kontrolné body, použité pre jednotlivé premenné, zobrazuje nasledujúca tabuľka (Tab. 25).

premenná	tvar a typ funkcie	a	b	c	d
wSLOPE	j - shaped, decreasing			0.0	3.0
wLR150	user fx				
wTCI	sigmoidal, symetic	0.0	3.5	5.5	8.0
wTNIVA	j - shape, decreasing			0.0	0.1
wTHRADISKA	sigmoidal, symetic	0.0	1.0	3.0	6.0

Tab. 25 – Hraničné body definujúce priebeh funkcií použitých v module FUZZY.



Obr. 34 – Vrstva časovej vzdialenosti od najbližšieho hradiska po pridelení váh.

Každá vrstva zvážených premenných predstavuje jednoduchý prediktívny model, v ktorom hodnota buniek predstavuje mieru preferencie príslušnej oblasti.

Pridelenie váh jednotlivým premenným a výpočet modelu


V programe IDRISI som za pomoci modulu MCE (Multi-Criteria Evaluation); (EASTMAN 2009b) skombinoval zvažené premenné do vrstvy ktorá predstavovala potenciál výskytu archeologických komponentov. V prvej fáze som vytvoril model (Model 1 - M1) prekryvom vrstiev za predpokladu, že ich vplyv na distribúciu komponentov v regióne bol rovnaký. Takouto kombináciou vznikne model súčtu potenciálov z jednotlivých vrstiev. V druhej fáze som sa snažil vytvoriť model, ktorý by reflektoval skutočnosť, že na distribúciu komponentov nevlývajú všetky premenné rovnakou mierou. K zníženiu vplyvu slabšie významných premenných a jeho zvýšeniu u premenných dôležitejších som využil možnosti modulu MCE. Tento umožňuje za použitia módu „weighted overlay“ (vážené prevrstvenie) jednotlivým vrstvám prideliť príslušné váhy¹⁶. Za týchto podmienok vznikol druhý model (Model 2 - M2) vyjadrujúci potenciálny výskyt komponentov s rôznymi mierami významnosti premenných. Potenciály jednotlivých vstupných vrstiev sú v takomto prípade násobené váhou príslušnej vrstvy.

Určenie hraníc medzi zónami rozdielneho potenciálu a optimalizácia modelov

Pri samotnej tvorbe prediktívnych modelov sa snažíme o čo najpresnejšie a najsprávnejšie predikovanie komponentov. Snažíme sa o najlepší model. Často hovoríme o výkone modelu teda o schopnosti modelu predikovať komponenty. Výkonný model by mal byť taký, aby dokázal s čo najväčšou efektívnosťou predikovať komponenty v zóne s vysokou pravdepodobnosťou výskytu komponentu. Práve veľkosť tejto zóny a percento zachytených komponentov v nej je hlavným kritériom pri rozhodovaní o výkonnosti modelu. V anglickej literatúre o prediktívnom modelovaní sa často hovorí o ACCURACY a PRECISION (VERHAGEN 2007, 119). Tieto dva termíny označujú základné charakteristiky kvality či akejsi výkonnosti modelu. Pojem accuracy je obecné prekladaný ako presnosť či ekzaktnosť. V prediktívnom modelovaní termín ACCURACY znamená správnosť predikcie: to či sa väčšina z nálezísk (komponentov) nachádza v oblasti s vysokou pravdepodobnosťou ich výskytu. V ideálnom prípade by model s najvyššou mierou ACCURACY mal v zóne s vysokou pravdepodobnosťou všetky komponenty (Obr. 35). Pojem PRECISION je tiež vnímaný ako presnosť, no rozumieme

¹⁶ Viac v oddieli "Pridelenie váh jednotlivým premenným" na strane 60.

pod ním skôr akúsi mieru presnosti. V prediktívnom modelovaní PRECISION odráža schopnosť modelu obmedziť plochu kategórie (zóny) s najvyššou mierou pravdepodobnosti na čo najmenšiu hodnotu. (VERHAGEN 2007, 119).



Obr. 35 – Rozdiel medzi termínom Acuraccy (správnosť) a Precision (presnosť).

V praxi sa často modely optimalizujú za účelom dosiahnutia vyššej správnosti (ACCURACY) či presnosti (PRECISION). S tým je často spojená aj úroveň chyby v predikcii respektíve risku, ktorý sme schopní akceptovať. Túto chybu môžeme vnímať ako neschopnosť nájsť komponent v kategórii. Chyba často rastie s veľkosťou kategórie. V kontraste s touto chybou je risk, že do kategórie nezarádime dôležitý komponent. Ten naopak s rastúcou rozlohou klesá.

Model s rozsiahlou zónou zvýšeného potenciálu výskytu komponent je vhodný pre účely pamiatkovej ochrany. V takomto prípade je risk, že dôležitá archeologická lokalita „spadne“ do zóny bez pamiatkovej ochrany nízky. Naproti tomu model, ktorý tieto zóny zredukuje na čo najmenšiu rozlohu, je vhodný na identifikáciu zákonitostí spojených s výberom miesta pre osídlenie, či vyhľadávanie nových lokalít. Risk, že stratíme komponent, je tu vykúpený zvýšenou pravdepodobnosťou, že nájdeme komponent nový.

Problémom teda je, že s rastúcou mierou správnosti klesá miera presnosti a naopak (KAMERMANS a kol. 2009, ; VERHAGEN 2009, 64). Cieľom je teda vytvoriť model, ktorý bude mať správnu mieru PRECISION aj ACCURACY.

Pre lepšie a prehľadnejšie zobrazenie výsledkov predikcie sa spojité vrstvy potenciálov zvyknú klasifikovať do tried. Hodnoty hraničných bodov kategórii sa prispôbujú potrebám spojeným s využitím modelu. V minulosti zaužívané kategórie nízkeho,

stredného a vysokého potenciálu (LOW, MEDIUM, HIGH); (DRESLER - MACHÁČEK 2008, ; GOLÁŇ 2001) sú vhodné skôr pre prediktívne modely vzniknuté prienikom booleanovských vrstiev. Rozdelenie do týchto kategórií však uľahčí interpretáciu aj mnou vytvoreného modelu.

Modely vzniknuté v tejto práci neboli tvorené zónami s pevnými hranicami rozdeľujúcimi oblasti na vhodné a nevhodné. Miera vhodnosti kontinuálne rástla či klesala podľa charakteru zvolenej funkcie v modulu FUZZY¹⁷, bez striktnej hranice.

Existuje viacero veličín uľahčujúcich takéto rozhodnutie. Medzi ne patrí skupina tzv. „GAIN“ hodnôt. Táto skupina kombinuje obe základné kritériá výkonu modelu, ACCURACY a PRECISION (VERHAGEN 2007, 134). Mieru úspešnosti predikcie tak možno pozorovať na vysokých hodnotách gain štatistik (GRAVES 2010, 9; VERHAGEN 2007, 134). Tieto veličiny charakterizujú vhodnosť použitia modelu a taktiež môžu slúžiť k vzájomnému porovnaniu modelov. Gain (prínos, zisk) vyjadruje akúsi efektívnosť zvolenej triedy v predikcii. V práci som použil tzv. Kvammeho gain (KVAMME 1988, 337).

$$G = 1 - \frac{p_a}{p_s}$$

Výraz 8 – Vzorec pre výpočet tzv. Kvammeho gain (KVAMME 1988).

V predchádzajúcom výraze (Výraz 8) p_a predstavuje podiel plochy triedy v rámci celého rozsahu a p_s je podiel komponentov v triede v rámci celkového počtu. Z definície vyplýva, že čím je plocha triedy menšia a počet komponentov v nej väčší, je hodnota „gain“ väčšia. Inými slovami, čím je G bližšie hodnote 1, tým je kategória v predikcii úspešnejšia. Použitie tejto štatistiky však nie je bezproblémové. Rovnakú hodnotu gainu môžeme dostať pri pomere 60/30 tak aj 80/40. V takomto prípade je len na základe gain hodnoty možné rozhodnúť ktorý model je „lepší-výkonnejší“.

Druhou zo štatistík je hodnota K_j . Tento výpočet prvý krát použila dvojica Wansleeben – Verhart (WANSLEEBEN - VERHART 1992, 107). Vo vzorci (Výraz 9) sa nachádzajú dve hlavné premenné. Prvá - p_s - je podiel komponentov zachytených v kategórii. Prestavuje

¹⁷ Modul FUZZY je súčasťou programu IDRISI, viac na strane 77

mieru úspešnosti modelu. Čím je p_s vyššie tým je model úspešnejší. Ideálom by bolo, keby model obsiahol všetky komponenty a hodnota p_s by sa rovnala 1.00. Druhou premenou je tzv. „relative gain“. Tá vychádza z rozdielu medzi podielom počtu komponent (p_s) a podielom plochy danej kategórie (p_a). Tento rozdiel dáva rámcovú predstavu o „zisku“ plynúcim z počtu komponentov nachádzajúcich sa oblasti o určitej veľkosti, teda o náraste počtu správne predikovaných komponentov s ohľadom na veľkosť územia. Ak model zachytí 100 percent komponentov na ploche rovnaj polovici skúmaného regiónu, potom tento rozdiel bude 50 percent (0,5). Čím je rozdiel väčší, tým je lepšia schopnosť modelu resp. zóny predikovať. Pridaním premennej, ktorá predstavuje zastúpenie plochy bez nálezov¹⁸ Wansleeben a Verhart (1992) vytvorili vzorec (Výraz 9), pomocou ktorého je možné identifikovať hranice zón potenciálu územia.

$$K_j = \sqrt{p_s \frac{p_s - p_a}{p_w}}$$

Výraz 9 – Vzorec pre výpočet hodnoty K_j (WANSLEEBEN - VERHART 1992).

$$P_w = 1 - (p_s - p_a)$$

Pri určovaní hraníc kategórií pre model Indicative Map of Archaeological Values (DEEBEN a kol. 1997, 82) autori vychádzajú z tzv. indicative value (I.v.). Táto predstavuje pomer medzi zastúpením komponentov v kategórii a jej podielom v rámci regiónu (Výraz 10). Vypočítaním I.v. pre každú z kategórií (HIGH, LOW) a dosadením týchto hodnôt do vzájomného pomeru získame predstavu ako pravdepodobnejší je výskyt komponentu v kategórii HIGH oproti LOW (Výraz 11). Tento kvocient je možné vypočítať aj v opačnom poradí. Teda ako viac je pravdepodobne, že komponentu nájdeme v oblasti označenej ako LOW oproti jeho výskytu v oblasti HIGH.

¹⁸ M. Wansleeben a L.B.M. Verhart jej hodnotu počítajú ako rozdiel medzi celkom a relatívnym ziskom. Teda v prípade, že 100 percent lokalít leží na území zaberajúcom iba 75 percent celej oblasti. Plocha ktorá je bez nálezov je potom 25 percent (WANSLEEBEN - VERHART 1992, 105).

$$I.v. = \frac{p_s}{p_a}$$

Výraz 10 - Vzorec pre výpočet tzv. Indicative value.

$$ratio\ I.v. = \frac{I.v._{High}}{I.v._{Low}}$$

Výraz 11 – Vzorec pre výpočet tzv. ratio I.v.

Určenie intervalov pre šírku jednotlivých tried je dôležitým krokom pri vyhodnocovaní modelu a miery jeho úspešnosti (výkonu). Je nutné rozhodnúť, aké hodnoty potenciálu je možno považovať za vysoké a od ktorej hodnoty je potenciál nevýznamný. V tejto fáze práce som sa rozhodol použiť klasifikačného kritéria z projektu „Mn/Model Statewide Archaeological Predictive Model“ (HOBBS a kol. 2002).

Pre modely M1 a M2 som sa rozhodol najskôr vytvoriť dve odlišné klasifikácie (ACCURACY a PRECISION). Ako referenčnú vrstvu som použil testovací súbor (TEST SAMPLE¹⁹). Tradičné rozdelenie modelu do troch kategórií som zamietol ako zbytočné. Kategória tzv. stredne veľkého potenciálu, označovaná ako MEDIUM, je pre výslednú silu modelu sama o sebe bezvýznamná. Predstavuje prechodnú oblasť medzi kategóriami HIGH a LOW. Samotná zóna MEDIUM nemá často žiadnu predikčnú silu a slúži k obmedzeniu rozlohy zvyšných zón (VERHAGEN 2009, 90).

Pri optimalizácii za účelom získania vyššej miery accuracy som kategóriu MEDIUM začlenil do zóny vysokého potenciálu (HIGH). Hranica tejto kategórie bola zvolená tak, aby v nej ležalo približne 85% komponentov. Zvyšok regiónu potom pripadol do zóny s nízkym potenciálom (LOW). Optimalizácia modelu s cieľom obmedziť veľkosť rozlohy tried so zvýšeným potenciálom sa riadila odlišnými pravidlami. Hlavným kritériom nebolo

¹⁹ Súbor komponentov, ktorý sa nepodieľal na tvorbe modelu a slúži na otestovanie úspešnosti modelu.

percentuálne zastúpenie komponentov v zóne, ale percentuálne zastúpenia tejto zóny v regióne. Hranicu potenciálu pre triedu, ktorá predstavuje vysoký potenciál (HIGH), som zvolil tak, aby rozlohou nepresiahla 10% plochy regiónu. Z malej rozlohy zóny HIGH je vidno že prechodná zóna MEDIUM bol začlenená do kategórie LOW.

Presné stanovenie hraníc tried podľa kritérií bolo nemožné. Komponenty sú len málokedy rozložené tak, že presne 85% z nich leží v jednej kategórii, alebo tak aby kategória pokrýva presne 10% regiónu. Pri stanovení hraníc som vyššie spomínané kritéria považoval za ideálny stav, ku ktorému sa som sa snažil priblížiť.

Prepočítaním hodnôt buniek z pôvodného formátu desatinných čísiel do formátu celých čísiel²⁰ vznikla v programe ArcGIS atribútová tabuľka. Táto reklasifikovala celú vrstvu do maximálneho počtu kategórii. Pre model M1 a model M2 tak vzniklo 98 resp. 97 kategórií. Program ArcGIS spočítal v rámci každej kategórie výskyt buniek s príslušnou hodnotou. Z tohto počtu bolo možné získať predstavu o percentuálnom zastúpení kategórie v rámci celej vrstvy (p_a z anglického proportion area), prípadne vynásobením počtu buniek plochou jednej bunky (0.0009 km^2) zistiť plochu každej z kategórii. Ovzorkovaním takto upravených modelov vrstvou archeologických komponentov (TEST SAMPLE) a následným vytvorením kontingenčnej tabuľky, zobrazujúcej počty komponentov v jednotlivých kategóriách som získal informáciu o percentuálnom zastúpení komponentov v týchto kategóriách (p_s z anglického proportion sites). Vzájomným spojením týchto dvoch informácií a vypočítaním kumulatívneho percenta pre polia P_s a P_a (Prílohy: Tab. 48 až Tab. 51) som mohol rozhodnúť o hraniciach jednotlivých kategórií.

Spodné hraničné hodnoty pre kategóriu najvyššieho potenciálu (HIGH) sú zobrazené v nasledujúcej tabuľke (Tab. 26). Hodnoty hraničných bodov v jednotlivých modeloch sú vzájomné neporovnateľné. Každý z modelov vznikol za iných podmienok a aj rozptyl hodnôt v nich je odlišný.

	ACCURACY	PRECISION
M1	38	67
M2	34	68

Tab. 26 – Hraničné hodnoty kategórie s najvyšším potenciálom (HIGH).

²⁰ Hodnota bunky bola pred prevodom vynásobená konštantou 100.

Testovanie výkonu modelov

Porovnávanie modelov predstavuje spôsob ako bližšie preskúmať ich výkon, prípadne rozhodnúť, ktorý z modelov je pre zamýšľaný účel vhodnejší. Výkon modelu chápem ako schopnosť modelu úspešne predikovať komponenty, ktoré neboli pri tvorbe modelu známe, respektíve sa na jeho tvorbe nepodieľali. Preto pri testovaní používam vrstvu komponentov označenú ako TEST SAMPLE. Postup testovania možno zhrnúť do nasledovných bodov.

1. Porovnával som, či existuje rozdiel medzi vybranými modelmi. V prípade, že rozdiel neexistoval znamenalo by to, že teórie, ktoré predstavujú oba modely sú vo výsledku zhodné a výkon modelu by mal byť teda u oboch rovnaký. Ak sú modely odlišné mal by sa líšiť aj ich výkon.
2. Odlišnosť a podobnosť modelov však treba bližšie preskúmať. Môžu byť spôsobené faktormi, ktoré pre výkon modelu nie sú dôležité. Podobnosť modelov môže byť spôsobená vysokým podielom plôch, ktoré sú na okraji záujmu napr. majú nízku hodnotu potenciálu. Ďalej treba preskúmať či je štatistický významný rozdiel dostačujúci k tomu, aby mal významný vplyv na výsledný vzhľad modelu.


Otázka vplyvu odlišných váh

Postup zvolený pre tvorbu modelu v tejto práci umožňuje dva druhy pridelenia váh. Toto „váženie“ predstavuje spôsob, akým sa z teoretickej roviny prenášajú predpoklady o preferencii istých oblastí do formátu vhodného pre spracovanie v prostredí GIS. Prvé váženie sa uskutočňuje v rámci premenných, kde sa jednotlivým kategóriám, či intervalom pridelujú odlišné miery dôležitosti na základe trendov sledovaných vo vstupných dátach. V tejto fáze práce som sa rozhodol otestovať teóriu o vplyve pridelenia odlišných váh vo váženom prekryve na výsledný model. Teda, či je pridelenie váh jednotlivým premenným pre tvorbu modelu dôležité. Testoval som tak druhý zo spomenutých spôsobov váženia.

Pre tento účel som využil kategorizáciu vzniknutú v predchádzajúcej kapitole. Testoval som rozdielnosť oboch modelov. Porovnával som model M1 optimalizovaný za účelom vyššej miery accuracy (Obr. 36) s modelom M2 (s rovnakou optimalizáciou); (Obr. 37).


ACCURACY	M1		M2	
	High	Low	High	Low
Ps	0.84	0.16	0.84	0.16
Pa	0.37	0.63	0.39	0.61
Kvamme Gain	0.56	-3.06	0.54	-2.94
indicative value	2.29	0.25	2.18	0.25
ratio i.v.	9.32		8.60	

Tab. 27 – Výsledky porovnávania modelu M1 a M2 optimalizovaných k vyššej miere ACCURACY.



Obr. 36 – Model M1.

Oba modely v triedach s najvyšším potenciálom úspešne predikovali 85% komponentov z testovacieho súboru na území o niečo väčšom ako tretina celkovej rozlohy (Tab. 27). Pri detailnejšom pohľade je zrejmé, že na predikciu približne 84% komponent bolo pri modeli M1 potrebné územie zaberajúce 37% z rozlohy regiónu. To je o nepatrné 2% menej ako v prípade modelu M2, ktorý na rovnaké percento (približne 84%) potreboval 39% plochy. Pri pohľade na „indicative value“ vyplýva, že model M1 si opäť vedie v predikcii lepšie. Tak isto pravdepodobnosť, že v zóne HIGH nájdeme komponent je 9.32 krát vyššia než pravdepodobnosť, že ho nájdeme v zóne LOW. Čo u modelu M2 je iba 8.6. Pri porovnaní hodnoty gain pre kategóriu LOW opakovane vychádza, risk zaradenia komponentu do kategórie LOW (VERHAGEN 2007, 134) je opäť nižší u modelu M1 (-3.06) zatiaľ čo u modelu M2 je táto hodnota vyššia (-2.94).



Obr. 37 – Model M2.

PRECISION	M1		M2	
	High	Low	High	Low
Ps	0.56	0.44	0.49	0.51
Pa	0.10	0.90	0.10	0.90
Kvamme Gain	0.82	-1.03	0.80	-0.76
indicative value	5.60	0.49	4.89	0.57
ratio i.v.	11.34		8.62	

Tab. 28 – Výsledky porovnávania modelov M1 a M2 optimalizovaných k vyššej miere PRECISION.


Pri porovnaní modelov optimalizovaných, tak aby kategórie s vysokým potenciálom u oboch modelov zaberali čo najmenšiu plochu územia (precision optimalizácia) bol rozdiel medzi modelmi ešte výraznejší (Tab. 28); (Obr. 36 a Obr. 37). Obom modelom sa podarilo predikovať na desatine územia okolo polovice komponentov. Model M1 je aj v tomto prípade v predikcii úspešnejší. Výrazne stúpila pravdepodobnosť výskytu komponentu v kategórii HIGH.

Na základe týchto porovnaní je možné tvrdiť, že rozdiel medzi modelmi je viditeľný. Pridelenie váh teda malo vplyv na výsledný model. Predikčná sila modelu M1 je v porovnaní s modelom M2 vyššia. Vzhľadom k výraznejšiemu rozdielu medzi modelmi pri porovnávaní optimalizovaných verzií s ohľadom na zvýšenie miery PRECISION je možné predpokladať, že model M1 je vhodnejší na vyhľadávanie neobjavených komponentov.

Otázka vplyvu blízkosti centrálnych miest


Ďalším cieľom práce bolo otestovanie teórie predloženej v práci Hospodárské zázemí raně středověkého centra na Pohansku u Břeclavi (DRESLER - MACHÁČEK 2008) v prostredí severného Slovenska. Táto predpokladá v oblasti južnej Moravy model štruktúry osídlenia, ktorý je do značnej miery závislý na existencii centrálnych sídlisk.

Za týmto účelom som vytvoril dva nové prediktívne modely. Prvý z modelov, model M3 (Obr. 38), predstavuje teóriu, v ktorej pri výbere polohy vhodnej pre osídlenie nebolo prihliadané na blízkosť centrálného sídliska. Pri tvorbe modelu som postupoval rovnakým spôsobom ako pri tvorbe modelu M2 s tým rozdielom, že do procedúry váženého prekryvu som nezaradil vrstvu časových vzdialeností od hradiska (THRADISKA).



Obr. 38 – Model M3.

Druhým vzniknutým modelom v tejto fáze práce bol model M4 (Obr. 39). Tento reprezentuje teóriu o vysokej atraktivite území do dvoch hodín od centrálného sídliska. Takto definovaný teoretický model som sa snažil zachytiť v podobe rastru zmenou váh intervalov v rámci vrstvy časovej vzdialenosti od hradísk a zmenou váhy celej vrstvy v rámci procedúry MCE.




Obr. 39 – Model M4.

Najprv som upravil priebeh funkcie v modulu FUZZY. Za najvhodnejšiu som pokladal sigmoidnú jednostranne klesajúcu krivku S. Výsledná vrstva (WTRAD2H) s hodnotami hraničných bodov uvedenými v nasledujúcej tabuľke (Tab. 29) dosahovala maximálnych hodnôt (1) v oblastiach vzdialených 0 hodín chôdze od hradiska. Tieto hodnoty postupne klesali až na minimálnu hodnotu (0) pre zóny vzdialené viac ako 2 hodiny chôdze od najbližšieho centra (Obr. 40).

premenná	tvar a typ funkcie	a	b	c	d
WTRAD2H	sigmoidal, decreasing	0	0	0	2.0

Tab. 29 – Hodnoty kontrolných bodov a typ funkcie zvolený pre výpočet vrstvy WTRAD2H.



Obr. 40 – Vrstva časovej vzdialenosti od najbližšieho hradiska po pridelení váh podľa tabuľky 29.

Následne som tejto vrstve pridelil v procese váženého prekryvu váhu rovnú 1. Hodnoty váh všetkých ostatných vrstiev zobrazené v tabuľke pod odstavom (Tab. 30), boli o polovicu menšie ako v prípade modelov (M2 a M3). Týmto som sa snažil zaistiť maximálny vplyv vrstvy nesúcej informáciu o blízkosti hradiska.

NAME	WEIGHT
WSLOPE	0.46
WTCI	0.33
WLR150	0.50
WTNIVA	0.47
WTHRAD2H	1.00
WFLORA	0.26
WSOIL	0.36

Tab. 30 – Hodnoty váh zvolené v procedúre MCE pri výpočte modelu M4.

Pre overenie existencie rozdielu medzi modelmi som za pomoci kappa koeficientu skúmal zmeny v rozdelení hodnôt v modely. Pred samotným porovnávaním som hodnoty v modeloch rozdelil do 3 kategórií. Hranice kategórii som určil tak, aby bolo možné porovnať oba modely. Kategória s najväčším potenciálom mohla zaberať iba 10 percent z plochy. Hranicu nadväzujúcej triedy (MEDIUM) som zvolil tak, aby kumulatívne percento správne predikovaných komponentov dosahovalo 85 %. Zvyšné hodnoty som priradil do intervalu (LOW) nízkeho potenciálu (Tab. 31). V tejto fáze porovnávania som sa pridržiaval tradičného rozdelenia na tri zóny potenciálu. Toto rozdelenie sa ukázalo ako vhodnejšie pre sledovanie zmien v klasifikácii buniek rastra a komponentov. Zároveň je takéto nastavenie hraníc kombináciou oboch hlavných kritérií (ACCURACY a PRECISION).

	HIGH	MEDIUM	LOW
Ps	-	85%	-
Pa	10%	-	-


Tab. 31 – Kritéria pre kategorizáciu modelov M3 a M4.

Prostredníctvom koeficientu kappa je možné sledovať mieru zhody medzi rastrami. Na výpočet som použil modul v CROSSTAB (EASTMAN 2009a) v programe IDRISI. Tento modul zároveň s výpočtom samotného koeficientu, porovnáva zmenu zastúpenia kategórií v rámci rastrov.

	Hraničné body		MEDIUM/HIGH		HIGH	
	MEDIUM	HIGH	Ps	Pa	Ps	Pa
M3	30	68	84%	41%	42%	10%
M4	27	51	84%	33%	56%	10%
M2	34	68	84%	39%	49%	10%

Tab. 32 – Hodnoty hraničných bodov a príslušné kumulatívne percentá pre jednotlivé kategórie.

V prvej fáze som vypočítal koeficient kappa pre oba celé modely. Pozoroval som zastúpenie kategórií v modeli M3 a porovnal som získané údaje so zmenami u modelu M4. Získal som tak predstavu o distribúcii kategórií v oboch modeloch. Na prvý pohľad je viditeľná podobnosť medzi zastúpeniami tried v rámci modelov (Graf 24). Z nasledujúceho grafu vyplýva podobné percentuálne zastúpenie kategórie v rámci každého z modelov. Toto je výsledkom optimalizácie kategórií na základe pravidiel z tabuľky (Tab. 31). Hranica kategórie HIGH je pevná a mení sa iba rozloha kategórií MEDIUM a LOW.



Graf 24 – Zastúpenie jednotlivých kategórií v modeloch M3 a M4.


V ďalšej tabuľke (Tab. 33) je detailne zachytená zmena zastúpenia kategórií v modeli M4 oproti modelu M3. Bunky pôvodne (v modeli M3) patriace do kategórie LOW zostali

z 97% v tejto kategórii aj v modely M4. Naproti tomu až 30% kategórie MEDIUM spadlo do kategórie LOW po pridaní vplyvu hradísk. Je pravdepodobné, že bunky patriace do tejto skupiny sa nachádzajú v príliš veľkej vzdialenosti od hradiska. Taktiež 13% zo zóny HIGH sa v tomto dôsledku dostalo do zóny MEDIUM. Aj tieto bunky predstavujú zóny, ktoré sa pravdepodobne vďaka veľkej vzdialenosti od hradiska stali nevhodnými pre osídlenie.

<u>Pa</u>	M3-low	M3-med	M3-high
M4-low	97%	30%	0%
M4-med	3%	65%	13%
M4-high	0%	5%	87%

Tab. 33 – Zmena zastúpenia kategórií v modeloch M3 a M4.

Situáciu dokresľujú hodnoty grafu (Graf 25) a nasledujúcej tabuľky (Tab. 34) ktoré predstavujú zmenu v predikcii komponentov. Výpočty dokazujú, že 14% komponentov bolo zaradených do kategórie MEDIUM. Teda možno povedať, že ležia vo sfére vplyvu hradiska. Taktiež necelých 40% z pôvodnej kategórie MEDIUM získalo hodnoty natoľko vysoké, že boli zaradené do kategórie HIGH. Naproti tomu 10% z komponentov ktoré pôvodne patrili do zóny s vysokou pravdepodobnosťou, sa dostalo do zóny so strednou mierou pravdepodobnosti, čo je opäť spôsobené ich vzdialenosťou od hradiska.



Graf 25 – Porovnanie zastúpenia kategórií v modeloch M3 a M4.

Ps	M3-low	M3-med	M3-high
M4-low	86%	6%	0%
M4-med	14%	56%	10%
M4-high	0%	39%	90%

Tab. 34 - Zmena zastúpenia predikovaných komponentov v modeloch M3 a M4.

Kappa Index of Agreement (KIA)	
Category	KIA
LOW	0.9128
MEDIUM	0.5439
HIGH	0.854
Overall Kappa	0.7355

Tab. 35 – Hodnoty koeficientu zhody kappa v kategóriách medzi modelmi M3 a M4 (testuje sa celý raster).

Vypočítaná hodnota koeficientu kappa medzi rastrami predstavujúcimi modely M3 a M4 sa rovná 73.55 %, čo značí veľmi dobrú mieru podobnosti (good agreement); (GRAPHPAD). Ak model M3 považujeme za referenčný, najnižšiu mieru zhody s modelom M4 pozorujeme v kategórii MEDIUM. V triede LOW je zhoda dostatočne výrazná (91%). To je do istej miery zapríčinené veľkým počtom buniek s nízkym potenciálom, ktorých počet sa v oboch modeloch zásadne nezmenil. Pri modelovaní kladieme dôraz predovšetkým na kategórie s vysokým potenciálom, zóny bez potenciálu zostávajú stranou.

Koeficient zhody v klasifikácii testovacieho súboru je už iba „primeraný“ (60.14%). Rovnako ako v predchádzajúcich prípadoch som k testovaniu použil súbor, ktorý sa na tvorbe nepodieľal (test sample). Jednalo sa teda o porovnávanie klasifikácie iba 45 buniek a výsledok je značne odlišný (Tab. 36). Zhoda je zase najslabšia v kategórii MEDIUM, ale došlo aj ku zoslabeniu zhody v triede s najvyšším potenciálom.


Kappa Index of Agreement (KIA)	
Category	KIA
LOW	0.8308
MEDIUM	0.375
HIGH	0.775
Overall Kappa	0.6014

Tab. 36 - Hodnoty koeficientu zhody kappa v kategóriách medzi modelmi M3 a M4 (testuje sa iba vrstva komponentov).

Z čísiel je očividné, že ku zmene v predikcii došlo jednoznačne. Oba modely sa výrazne odlišujú. Model M4 dokáže v porovnaní s modelom M3 na rovnako veľkej ploche (10%) predikovať podstatne vyššie percento komponent.

	M3-low	M3-med	M3-high	Celkom
M4-low	13%	2%	0%	16%
M4-med	2%	22%	4%	29%
M4-high	0%	16%	40%	56%
Celkom	16%	40%	44%	100%

Tab. 37 - Zmena percentuálneho zastúpenia predikovaných komponentov v modeloch M3 a M4.



Graf 26 – Zastúpenie predikovaných komponentov v kategóriách v modeloch M3 a M4.

S ohľadom na tieto výsledky môžeme tvrdiť, že model M4 predstavuje v predikcii úspešnejšiu teóriu. Je teda pravdepodobné, že distribúcia komponent je ovplyvnená polohou centrálnej komponenty, jej blízkosťou či naopak vzdialenosťou k centrálnemu sídlu.

V snahe preskúmať tento výsledok detailnejšie som sa rozhodol porovnať oba modely (M3 a M4) za pomoci gain štatistík. Vychádzal som z kategorizácie, ktorú som použil v predchádzajúcom porovnaní (Tab. 31).

Ako prvú som porovnal výkonnosť modelov optimalizovaných na vysokú mieru ACCURACY. Do kategórie HIGH som tak začlenil aj zónu MEDIUM. V tejto spojenej kategórii oba modely predikovali 84% komponentov. Rozdiel bol však vo veľkosti týchto zón. Ako ukázala gain štatistika model M4 je v porovnaní s modelom M3 úspešnejší. Hodnota gain pre zónu s vysokým potenciálom je u modelu M4 0.61, čo v porovnaní s hodnotou 0.51 pre model M3 je výsledok podstatne lepší. Rovnako pravdepodobnosť výskytu komponenty v zóne HIGH je skoro 11 krát vyššia ako pravdepodobnosť, že sa komponentu bude nachádzať v zóne LOW. Čo je oproti hodnote 7.8 z modelu M3 zase dôkazom lepšej výkonnosti (Tab. 38).

<u>Accuracy</u>	M2		M3		M4	
	High	Low	High	Low	High	Low
Ps	0.84	0.16	0.84	0.16	0.84	0.16
Pa	0.39	0.61	0.41	0.59	0.33	0.67
Kvamme Gain	0.54	-2.94	0.51	-2.79	0.61	-3.29
indicative value	2.18	0.25	2.06	0.26	2.54	0.23
ratio i.v.	8.60		7.80		10.88	

Tab. 38 – Výkon modelov M2, M3 a M4 s ACCURACY optimalizáciou.

K preskúmaniu výkonu modelov v oblasti pokrývajúcej iba 10% z vyčleného územia, som triedy upravil tak, že pôvodná kategória MEDIUM bola začlenená do triedy LOW. Testoval som tak výkon modelov optimalizovaných s ohľadom na PRECISION. Aj v tomto prípade je model M4 úspešnejší. Hodnota gain je opäť vyššia a lepší výkon modelu naznačuje aj hodnota pomeru (ratio i.v.); (Tab. 39). Pozoruhodné je, že zatiaľ čo sa hodnota tohto pomeru u modelu M3 oproti prechádzajúcemu porovnaniu zmenšila u modelu M4 táto hodnota vzrástla. To dokazuje že model M4 je v samotnej kategórii HIGH (10% oblasti) úspešnejší ako v kategórii MEDIUM+HIGH. Môžem teda predpokladať, že komponenty sa

v modely M4 sústreďujú skôr v oblastiach s najvyšším potenciálom. Model je teda presnejší, a dokáže predikovať komponenty s väčšou spoľahlivosťou.

Precision	M2		M3		M4	
	High	Low	High	Low	High	Low
Ps	0.49	0.51	0.42	0.58	0.56	0.44
Pa	0.10	0.90	0.10	0.90	0.10	0.90
Kvamme Gain	0.80	-0.76	0.76	-0.56	0.82	-1.02
indicative value	4.89	0.57	4.21	0.64	5.48	0.49
ratio i.v.	8.62		6.55		11.08	

Tab. 39 – Výkon modelov M2, M3 a M4 s optimalizáciou PRECISION.

Z výsledkov porovnaní je zreteľné, že model bez vplyvu hradísk je v predikcii o mnoho slabší. V kategórii HIGH na ploche 10 % dokáže predikovať približne 42% komponentov čo je v porovnaní s modelom, ktorý počíta s vplyvom hradísk na štruktúru osídlenia (56%) podstatne menej.

Na základe tohto zistenia som sa pokúsil porovnať model (M2) vzniknutý zo všetkých dostupných premenných na základe postupov predložených v stati „Postup pri vytváraní modelu“²¹ a model s výrazným vplyvom blízkosti hradísk (M4).


Aj napriek tomu že model M1 dosahuje pri predikcii oproti modelu M2 lepších výsledkov. Rozhodol som sa pre použitie modelu, ktorý vznikol prostredníctvom váženého prekryvu za priradenia rôznych váh k jednotlivým premenným.

Keďže model M2 vznikol indukčnou metódou na základe tendencií pozorovaných v dátach, bude v porovnaní figurovať ako referenčný súbor. Tento model považujem za odraz stavu osídlenia ako ho poznáme teraz. Porovnaním výkonu modelu M4 budem sledovať, či hypotéza²², na základe ktorej model vznikol, je možná. Pri porovnávaní modelu prostredníctvom kappa koeficientu budem pracovať s kategorizáciou definovanou v tabuľke na strane 101 (Tab. 31).

²¹ Viac na strane 19.


²² Predpoklad, že vplyv hradísk na štruktúru osídlenia je výrazne silnejší ako vplyv ostatných premenných. (viac na strane 97).

Ako prvé som opäť porovnal celé vrstvy modelov v module CROSSTAB. Na prvý pohľad je jasná zmena v zastúpení kategórie LOW. U modely M4 je táto kategória približne o 5% väčšia ako pri modeli M2. Týchto 5% predstavuje zhruba 430 km², čo je približne toľko ako rozloha okresu Považská Bystrica. Význam tohto ešte vynikne v kontraste s veľkosťou kategórie HIGH, ktorej maximálna rozloha bola stanovená na 10%. Rovnako významný rozdiel je vo veľkosti zóny MEDIUM. V tomto prípade však kategória MEDIUM v modely M2 je o 5% väčšia ako v modely M4. Veľkosť kategórie HIGH bola pevne nastavená (10%) a jej veľkosť je u oboch modelov zhodná. Z nasledujúceho grafu (Graf 27) vyplýva, že zóna LOW sa v modely M4 zväčšila na úkor zóny MEDIUM, pričom v modely M2 nastal opačný stav.




Graf 27 – Porovnanie zastúpenia kategórii v modeloch M2 a M4.

Porovnaním kategorizácie testovacieho súboru sa zistilo, že do kategórie LOW bolo v oboch prípadoch zaradených iba 15% komponentov. To opäť odráža pravidlá uplatnené pri klasifikácii, kde 85% komponentov by malo patriť do kategórií MEDIUM a HIGH. V kategórii MEDIUM je výkon modelov v zásade rovnaký. Model M4 síce predikuje oproti modelu M2 menšie percento komponentov (M4=29%; M2=33%), ale táto kategória má v modely aj menšie zastúpenie. Naproti tomu pri rovnakej veľkosti kategórie HIGH, sa model M4 ukázal v predikcii ako úspešnejší, keď zachytil 56% oproti 51% komponent (Graf 28).



Graf 28 – Zastúpenie kategórií v modely M2.



Graf 29 – Zastúpenie kategórií v modeli M4.

Na základe kappa koeficientu zhody môžeme tvrdiť, že medzi jednotlivými rastovými vrstvami je miera zhody „veľmi dobrá“ (76.8%). Táto zhoda je zase spôsobená veľkým rozsahom zóny LOW, kde sa oba rastre v podstate zhodujú. Pri porovnaní kategorizácie testovacieho súboru naznačuje kappa koeficient zhodu iba 51.49%, čo predstavuje iba „primeranú“ mieru zhody.


Predchádzajúcimi testami som zistil, že medzi modelmi M2 a M4 je skutočný rozdiel. Pri pohľade na tabuľky uvedené vyššie (Tab. 38, Tab. 39) je opäť zrejmé, že model M4 je v oboch kritériách (ACCURACY, PRECISION) úspešnejší.

Napriek tomu, že výkon oboch modelov bol v rámci spojenej kategórie MEDIUM/HIGH rovnaký (oba predikovali 85%), model M4 dokázal tohto výkonu dosiahnuť na menšej ploche. V samotnej kategórii s najvyšším potenciálom (HIGH) predikoval vyššie percento komponentov ako model M2. S ohľadom na vyšší výkon modelu M4 je možné považovať hypotézu o koncentrácii sídlisk v okolí 2 hodín chôdze od hradiska za prijateľnú. Na základe výsledkov nie je možné túto teóriu vyvrátiť.

Porovnanie optimalizovaných modelov

Termín optimalizácia modelu predstavuje nastavenie hraníc medzi jednotlivými kategóriami tak, aby zodpovedali príslušným požiadavkám. Požiadavky sa líšia od účelu pre ktorý je model tvorený. Počet kategórii môže byť ľubovoľný a samotná optimalizácia je nezávislá na postupe tvorby modelu. Rovnakými pravidlami môžeme optimalizovať booleanovský model či model s mierou potenciálu vo forme spojitej vrstvy. Optimalizáciou som sa snažil upraviť model tak, aby mal čo najlepší výkon.

Ako prvý som optimalizoval model M2, ktorého vznik ovplyvnili rôzne miery dôležitosti premenných a podieľali sa na ňom všetky signifikantné premenné. Model som sa rozhodol optimalizovať tak, aby mali dostatočnú presnosť aj správnosť²³, k čomu som použil súbor dát z TEST SAMPLE. Nastavenie hraníc kategórii tvoriacich zóny s nízkou, strednou a vysokou mierou potenciálu som zvolil za pomoci miery gain, hodnoty K_j a subjektívnej korekcie s ohľadom na požiadavky výkonu modelov.



Graf 30 – Priebeh hodnôt gain pre model M2. Os x predstavuje hodnoty buniek v modeli M2.

²³ Viac k termínom v kapitole Určenie hraníc medzi zónami rozdielneho potenciálu na strane 88.

Kedže sa snažíme o definovanie zón, ktoré sú v predikcii najúspešnejšie, na osi x postupujem v smere od 100 k 0. Z hodnôt v nasledujúcom grafe (Graf 30) jasne vyplýva, že obe premenné, K_j aj „relative gain“ javia podobnú tendenciu. Hodnoty narastajú od nuly po prvé maximum pri hodnote 63. Pod touto hranicou hodnoty gain striedavo klesajú a stúpajú až dospejú k maximálnej hodnote. V tejto fáze vlastne hľadáme spodnú hranicu pre kategóriu HIGH. Ide teda o model s veľkou mierou PRECISION. V nasledujúcej tabuľke (Tab. 40) vidíme, že ak by sme zvolili spodnú hranicu na hodnote 63, bola by hodnota Kvammeho gainu s pomedzi ostatných najvyššia. Taktiež šanca, že komponent nájdeme skôr v kategórii HIGH ako LOW, je u takto zvolenej zóny najvyššia (12.68).

PRECISION	M2	hr63	M2	hr58	M2	hr53
	High	Low	High	Low	High	Low
Ps	0.64	0.36	0.67	0.33	0.69	0.31
Pa	0.13	0.87	0.16	0.84	0.19	0.81
Kvamme Gain	0.81	-1.46	0.77	-1.53	0.72	-1.60
indicative value	5.15	0.41	4.30	0.39	3.61	0.38
ratio i.v.	12.68		10.89		9.39	

Tab. 40 – Porovnanie výkonov zón pre jednotlivé hraničné hodnoty v modeli M2.

Hodnotu 63 som zvolil ako spodnú hranicu pre zónu s najvyšším potenciálom. V prípade, že by som za hranicu zvolil niektorú z hodnôt 58 či 53, kde hodnoty gain oscilujú, pomer plochy a predikovaných komponentov by nebol tak výhodný ako práve pri hodnote 63.

Do takto definovanej kategórie spadajú plochy rastra modelu M2 s hodnotou väčšou alebo rovnou hladine 63. Pomer plochy tejto kategórie voči celku je 0,125 (12,5% plochy z územia). Na takto slabo zastúpenej oblasti model úspešne predikoval viac než 64,4 % komponentov (Tab. 40). Hodnoty oboch mier zisku (Kvammeho Gain, relatívny gain) tu dosahujú lokálnych maxím. Ako dolnú hranicu zóny so stredným potenciálom som zvolil hodnotu 46. Pri tejto hodnote dosahujú všetky indikátory maximálny zisk. Je možné, že plochy s hodnotou väčšou alebo rovnou ako 46 predstavujú z hľadiska úspešnosti predikcie oblasť, kde sa nachádza 78% komponentov na ploche, ktorá reprezentuje iba štvrtinu celého regiónu (Tab. 41). Tento interval však obsahuje aj hodnoty patriace do kategórie s najvyššou prioritou (HIGH). Samotná zóna stredného potenciálu s hranicami v rozmedzí 46 až 63 pokrýva zhruba rovnakú plochu (12,43) ako zóna najvyššieho

potenciálu. Počet komponentov je však výrazne menší, iba o niečo viac ako 13 % (13,33) komponentov. V nasledujúcej tabuľke (Tab. 41) zóny HIGH a MEDIUM kombinujem a vytváram model s veľkou mierou ACCURACY. Zóna s nízkym potenciálom síce obsahuje dvojnásobné množstvo komponentov ako samotná zóna MEDIUM, ale je čo do plochy viac ako šesť krát tak veľká. Index významnosti je v tejto (LOW) zóne najmenší (Tab. 42).

ACCURACY	M2	hr46
	High	Low
Ps	0.78	0.22
Pa	0.25	0.75
Kvamme Gain	0.68	-2.38
indicative value	3.12	0.30
ratio i.v.	10.54	

Tab. 41 – Výkon modelu M2 rozdeleného na zóny HIGH a LOW hodnotou 46.

	%Komponent	%Plochy	Index_Vyznamnosti
LOW	22,22	75,06	0,30
MEDIUM	13,33	12,43	1,07
HIGH	64,44	12,51	5,15

Tab. 42 – Index významnosti pre optimalizované kategórie.

M2	High/Medium – hranica 46				High – hranica 63			
	%AREA	%Komp	Gain	Kj	%AREA	%Komp	Gain	Kj
	25	78	0.68	0.93	13	64	0.81	0.83

Tab. 43 – Prehľadné zobrazenie výsledkov optimalizácie modelu M2.

Vzhľadom k použitiu testovacieho súboru (TEST SAMPLE) pre definovanie hraníc jednotlivých kategórií je proces klasifikácie možno považovať za istú formu testovania výkonu modelu (Tab. 43).

Ako druhý som optimalizoval model M4. Tento sa pri prechádzajúcom porovnávaní s modelom M2 ukázal ako úspešnejší. Je však možné, že hranice kategórií stanovené podľa tabuľky uvedenej vyššie v texte (Tab. 31) neboli nastavené „fair“. Mohlo dôjsť k tomu, že pevným stanovením limitu 10% z plochy pre kategóriu HIGH a 85% z komponentov pre spojenú kategóriu MEDIUM+HIGH, sme vytvorili podmienky, ktoré skôr vyhovujú modelu M4. Napríklad pri pohľade na tabuľku v prílohe (Tab. 49) vidieť že, ak by sme hranicu kategórie HIGH posunuli tak aby mohla zaberať 11% z územia, výkon by sa výrazne zlepšil. Pre takto limitovanú zónu model predikuje až 60% z komponent. A je v tomto prípade úspešnejší ako model M4.

Práve optimalizáciou modelu sme schopní odhaliť intervaly s najlepším pomerom predikovaných komponentov k rozlohe. Optimalizáciou tak dávame rovnakú šancu obom modelom ukázať svoju silu.

Hranice kategórií som podobne ako v prípade predchádzajúcej optimalizácie zvolil za pomoci kombinácie hodnôt K_j a Kvammeho gainu. Spodná hranica pre zónu HIGH bola stanovená na hodnote 51. V tejto zóne zaberajúcej iba 10% rozlohy územia dokáže model predikovať 56% komponentov. Ako spodnú hranicu zóny MEDIUM som zvolil hodnotu 43. V spojenej kategórii (MEDIUM+HIGH) zahrnujúcej bunky rastra s hodnotami 43 až 99 model predikuje 71% komponent na území zaberajúcom 16% z oblasti. V nasledujúcej tabuľke (Tab. 44) tak môžeme porovnať výkon oboch modelov v kategórii HIGH. V tomto prípade sa ukazuje, že model M2 je pri predikcii síce menej úspešný, ale je 12.68 krát pravdepodobnejšie, že nájdeme komponent v kategórii HIGH a nie v kategórii LOW. U modelu M4 je táto šanca iba 11.08.

<u>PRECISION</u>	M2	hr63	M4	hr51
	High	Low	High	Low
Ps	0.64	0.36	0.56	0.44
Pa	0.13	0.87	0.10	0.90
Kvamme Gain	0.81	-1.46	0.82	-1.02
indicative value	5.15	0.41	5.48	0.49
ratio i.v.	12.68		11.08	

Tab. 44 - Porovnanie výkonu modelov M2 a M4 s precision optimalizáciou.

Ak do zóny najpravdepodobnejšieho výskytu zahrnieme aj kategóriu MEDIUM, ako vhodnejší model sa ukáže model M4. S 71% komponentami je tento na 16% rozlohy skúmaného regiónu možné považovať za veľmi úspešný (Tab. 45).

<u>ACCURACY</u>	M2	hr46	M4	hr43
	High	Low	High	Low
Ps	0.78	0.22	0.71	0.29
Pa	0.25	0.75	0.16	0.84
Kvamme Gain	0.68	-2.38	0.78	-1.91
indicative value	3.12	0.30	4.46	0.34
ratio i.v.	10.54		12.96	

Tab. 45 – Porovnanie výkonu modelov M2 a M4 s accuracy optimalizáciou.

Výsledky

Testovanie výkonu a porovnávanie rôznych modelov pomocou gain štatistík dopomohlo k odhaleniu skutočnej sily každého z modelov. Oba modely (M2 a M4) považujem za úspešné. Ich výkon je dostačujúci k podmienkam a kvalite vstupných zdrojov, z ktorých vznikli. Ich vytvorenie môže byť jedným z prvých krokov k poznaniu štruktúry sídlisk v včasnom stredoveku v skúmanej oblasti. Skutočnosť, že oba z modelov dokážu úspešne predikovať neznáme komponenty, naznačuje existenciu podobných trendov v testovacom aj dizajnovom súbore. Je teda pravdepodobné, že isté zákonitosti pri výbere miesta vhodného pre založenie sídliska boli dodržované. Na otázku, čo presne viedlo k výberu týchto miest je však na základe súčasných poznatkov nemožné odpovedať.

Z celkového počtu 91 komponentov, nachádzajúcich sa na území spracovávaného regiónu model M2 v kategórii najvyššieho potenciálu (HIGH) predikuje 62 komponentov, čo je 68% ak k tejto kategórii pripojíme aj kategóriu so stredným potenciálom, je model úspešný na 79%. Táto spojená kategória predstavuje približne štvrtinu celého územia. Podobný výsledok dosahuje aj model M4, ktorý na 16% územia predikuje 72% z komponentov. Oba výsledky je možno spolu s percentuálnym podielom komponentov pozorovať v nasledujúcej tabuľke (Tab. 46).

	Počet komponentov		%	
	M2	M4	M2	M4
LOW	19	25	21%	27%
MED	10	12	11%	13%
HIGH	62	54	68%	59%

Tab. 46 – Prehľad výsledkov modelov M2 a M4.

Predikciou sa mi podarilo odhaliť komponenty, ktoré zo spoločného trendu ostatných sídlisk vybočujú. Jedná sa zhruba o 21% respektíve 27% komponentov, ktoré sa nachádzajú v zóne s nízkym potenciálom. Príčiny, ktoré viedli k zaradeniu týchto komponentov do tejto kategórie, môžu predstavovať faktory, ktoré sa mi v priebehu spracovania vstupných dát nepodarilo správne rozpoznať.

	M4-LOW	M4-MED	M4_HIGH	Celkom
M2-LOW	14	1	4	19
M2-MED	9			9
M2-HIGH	2			2
Celkom	25	1	4	30

Tab. 47 – Zmena v kategorizácii komponent nachádzajúcich sa v zóne LOW v modely M2 alebo M4.

Aby som detailnejšie preskúmal príčiny takéhoto zaradenia dotazom do vrstvy všetkých archeologických komponentov (91 komponentov) som vybral také, ktoré boli v modely M2 alebo M4 zaradené do zóny LOW. V predchádzajúcej tabuľke (Tab. 47) je zreteľné zastúpenie jednotlivých komponentov v rámci sledovaných kategórií. Tieto kategórie sú výsledkom optimalizovania modelov za účelom najvyššieho výkonu v kategóriách HIGH a MEDIUM. Štrnásť komponentov leží v triede LOW v oboch modeloch. Pri detailnom pohľade na konkrétne komponenty som zistil, že sa zväčša jedná o náleziská bez presnejšie určenej predpokladanej funkcie. V katalógu P. Mila (2000) boli označené ako „SI(?)“, čo predstavuje nejednoznačné označenie sídliska. Modely nám pomohli odhaliť radu komponentov, ktoré boli pôvodne označené ako sídliská ale na základe ich špecifickej polohy sa ukázalo, že majú skôr vzťah ku blízkemu hradisku či sú priamo jeho súčasťou.

S pomedzi týchto 14 komponentov vyčnieva skupina 3 lokalít nachádzajúcich sa v katastrálnom území obce Pruské – Vršatské Podhradie (MORAVČÍK 1976, ; NEŠPOROVÁ 1986, 167; PETROVSKÝ-ŠICHMAN 1964a, 180). Skupina pravdepodobne tvorí jeden spoločný komplex. Včasno stredoveké osídlenie tejto doliny bolo dokázané zisťovacím výskumom v roku 1965 (FURMÁNEK 1970). Pomerne časté nálezy ranne stredovekej keramiky ako aj hromadný nález železných predmetov indikujú existenciu sídliska. Toto sídlisko však vzhľadom k odlišným parametrom prostredia nezapadlo do trendu nastaveného ostatnými sídliskami v regióne. Ani jeden z modelov nedokázal odhaliť sídelný potenciál doliny.

Za zaujímavú anomáliu považujem polohu „Horné Pažite“ u obce Nitrianske Rudno (BIALEKOVÁ 1992, 111). Lokalitu skúmal J. Porubský v roku 1957. Komponent má všetky predpoklady byť „typickým“ sídliskom. Je vzdialený približne 200m od prameňa miestneho potoka. Nachádza sa v malej kotline na úpätí vrchov Malý a Veľký Rokoš. Napriek tomu oba modely polohu, kde sa nachádza, klasifikovali ako bez potenciálu. Samotný komponent sa nachádza približne 1 kilometer od hranice najvyššieho

potenciálu. Je pravdepodobné, že výber tohto miesta sa riadil inými podmienkami ako v ostatných prípadoch. Avšak vďaka blízkosti zóny HIGH môžeme považovať nepresnosť vstupných dát za ďalšiu z možností vzniku tejto anomálie. Podobným prípadom je poloha „Skalky“ u Rajeckých Teplíc. V literatúre (BIALEKOVÁ 1992, 193) je poloha popisovaná ako terasa. Túto terasu však v digitálnom výškopisnom modeli ani v odvodených vrstvách nie sme schopní identifikovať. Svah v okolí bunky dosahuje hodnoty 24°. Táto hodnota je pre osídlenie nevhodná a vzhľadom k veľkej váhe vrstvy SLOPE bola oblasť identifikovaná ako bez potenciálu.

V súpisu komponent (Tab. 54) sú zahrnuté základné údaje o „nesprávne“ predikovaných komponentoch. Komponent ležiaci na mieste s najhorším potenciálom z pomedzi všetkých komponentov v modeli M2 je poloha „hrad Hričov“ v katastri obce Hričovské Podhradie. Výskum J. Moravčíka v roku 1993 (MORAVČÍK 1995) potvrdil nálezy včasnostredovekej keramiky, avšak iba v sekundárnych pozíciách. Podobne aj u náleziska z polohy „Hradište“ z katastra Považského Podhradia (BIALEKOVÁ 1992, 87), „Hrad“ z obce Ledce (BIALEKOVÁ 1992, 82) a „úpätie Hradiska“ pri obci Kral'ovany (BIALEKOVÁ 1992, 19) sú nálezy zastúpené len nevýraznými fragmentmi keramiky. Na týchto polohách je možno očakávať včasnostredoveké osídlenie, avšak charakter týchto sídlisk sa nutne odlišoval od väčšiny úspešne predikovaných. Je pravdepodobné, že vďaka ich polohe, sa jednalo o komponenty špeciálneho významu, možno strategického charakteru. Pri nálezisku z katastra Prievidza - Štvrte polohy „Pod hradskou“ je možné očakávať sídlisko súvisiace s neďaleko ležiacim hradiskom. Ťažisko osídlenia celej lokality spadá do 1. storočia nášho letopočtu, avšak hradisko bolo osídlené aj v včasnom stredoveku (RUTTKAY 1965, 193-199; RUTTKAY 1966, 14). Je zaujímavé že aj napriek bezprostrednej blízkosti sídliska k hradisku (70 metrov vzdušnou čiarou) jeho potenciál nie je dostatočne vysoký ani v prípade modelu M4.

Lokalita Blatnica, poloha „Plešovica“ (BIALEKOVÁ 1992, 54) môžeme predpokladať, že zaradenie komponentu do skupiny sídliska bolo chybné. Výrazná poloha v krajine naznačuje, že sa s veľkou pravdepodobnosťou jedná o hradisko. Bližšie informácie o komponente sa mi nepodarilo získať, keďže existujú iba vo forme nálezovej správy uloženej v archíve SAV v Nitre.

Zaujímavú situáciu ilustruje komponent z polohy „Laz pod Malenicou“ v katastri obce Beluša. Jedná sa o sídlisko ležiace pri sútoku dvoch potokov. V jeho blízkosti sa nachádza mohylník z prelomu 8.-9. storočia (BIALEKOVÁ 1992, 73; PETROVSKÝ-ŠICHMAN 1964b, 60). Aj napriek tomu, že poloha bola v modeli M2 zaradená do kategórie s nízkym potenciálom, leží tesne pri hranici s kategóriou MEDIUM. Okolie komponentu je taktiež

považované modelom M2 za vhodné pre výber miesta pre sídlisko. Úplne odlišná situácia však nastáva pri modele M4. Celá oblasť sa nachádza príliš ďaleko od najbližšieho hradiska a stráca tak potenciál pre osídlenie. Túto zmenu je možné pozorovať aj u nálezisk Bolešov, poloha „V ohradách“ (BIALEKOVÁ 1992, 75) a Púchov, poloha „Dráhy pod Hôrkou“ (BIALEKOVÁ 1992, 92). Oba komponenty svojim potenciálom spĺňajú predpoklady pre umiestenie sídliska pre model M2. Avšak pri akceptovaní teórie o nutnej blízkosti hradiska tento potenciál strácajú.

Opačným prípadom sú komponenty: Košeca „Tehelna“, Žilina „Porúbka-dolina na ľavom brehu Rajčianky“ a „Turie – Za hrádek“, Divinka „Ohrádza- Zábeh“ (BIALEKOVÁ 1992, 80, 198, 199, 187). Všetky ležia v blízkosti hradiska a potenciál ich okolia sa výrazne zvýšil práve pridaním váh vrstve časových vzdialeností od hradísk.

Práve odhalenie takto protichodných potenciálov je jedným z prínosov predkladanej práce. Jedná sa vlastne o výnimky (anomálie) z teórie. Ich existencia je dôkazom o platnosti jednej teórie a zároveň vyvracia platnosť alternatívnej teórie. Tento stav nás núti ďalej skúmať štruktúru osídlenia a vytvárať nové teórie a zároveň tak vytvárať priestor pre odlišné a doplňujúce interpretácie štruktúr vyčnievajúcich z predikovaného rámca (KUNA 1996, 584).

Na základe predložených výsledkov predpokladám:

1. Pridelenie váh má vplyv na výsledok modelovania. Tento vplyv je však veľmi slabý. Rozdiely medzi modelmi sú iba minimálne. Z pohľadu výkonu sa líšia v správnej predikci rádovo o 2 komponenty.
2. Štruktúru osídlenia je možné vysvetliť atraktivitou polôh v blízkosti hradísk. Testy preukázali, že model predstavujúci túto teóriu je možný. Pôvodný účel príslušných centrálnych miest a ich pozíciu v sídliskovej hierarchii však môžeme iba odhadovať (DRESLER - MACHÁČEK 2008, 144).

Diskusia a kritika

Prediktívne modely krajiny vytvorené v tejto práci pokladám za prvý krok pre poznanie stratégií osídlenia v skúmanom regióne. Prostredníctvom modelov som skúmal faktory vedúce k výberu miesta osídlenia v období včasného stredoveku. Modely môžu v budúcnosti slúžiť ako vstupná vrstva nahradzujúca vrstvu archeologických komponentov pri analýze vývoja osídlenia a predstavujúca tak súvislú vrstvu pravdepodobnosti osídlenia (KUNA 1996, 586).

Pri tvorbe archeologického predikčného modelu komponentov nie je cieľom vytvorenie presnej rekonštrukcie (reálneho obrazu) archeologickej krajiny, ale identifikácia relevantných informácií, faktorov, vzťahov, ich zasadenie do reálnych skutočností a následné testovanie pomocou nových dát. Prediktívne modely sú iba kroky slúžiace k priblíženiu sa k rekonštrukcii historickej reality. Slúžia hlavne k umiestňovaniu hypotéz do reálnych rozmerov a preto zatiaľ nemôžu reflektovať historickú realitu. Je nutné mať na pamäti, že sa vždy ide len o model, vychádzajúci z poznania obecných trendov a zákonitostí. Tento model sa musí líšiť od skutočnosti, pretože nie je možné postihnúť individuálnu variabilitu na úrovni individuálnych lokalít a udalostí (KUNA 2004, 487; OCHRANA 2009, 49; POPPER 1997). Tento predpoklad platí hlavne v prípade modelov vznikajúcich metódou indukcie. Práve tento postup som zvolil pri tvorbe predkladaného modelu. Akokoľvek je indukčná metóda kritizovaná (POPPER 1997) z môjho pohľadu je základným a prvým krokom v poznávaní a riešení každého problému. To, čo o probléme vieme, poznáme buďto priamo z vlastnej skúsenosti alebo sprostredkovane. Spôsob, ako s touto vedomosťou naložíme a ako tento poznatok pretransformujeme do prediktívneho modelu je však rozhodujúci. V mojom prípade som predpokladal, že časté opakovanie určitého vzorca v rozmiestení archeologických komponentov bolo dôsledkom vedomej či podvedomej preferencie určitých faktorov. Predpokladal som teda určitú mieru korelácie medzi miestami vhodnými pre osídlenie a vybranými premennými. Aj napriek tomu, že takýto prístup umožňuje predikciu iba často sa opakujúcich javov, sledovaných na väčšom počte komponentov, pokladám ho v tejto fáze bádania za dostačujúci (WHITLEY 2005, 124).

Pri tvorbe modelov som odhalil viaceré nedostatky v metóde a vo vstupných dátach:

1. Pri tvorbe modelov som postupoval induktívnou metódou. Základným problémom spojeným s indukciou je tvorba všeobecných modelov z elementárnych poznatkov. Akokoľvek často opakovaná skutočnosť nedáva záruku, že tento stav

sa bude opakovať aj v budúcnosti. Počet pozorovaní ma účinok iba na nasledujúce pozorovanie. Preto aj vypovedajúca hodnota môjho modelu je obmedzená. Model dokáže predikovať iba také archeologické areály, z akých bol vytvorený. Do tvorby modelu som teda zahrnul také komponenty, u ktorých predpokladám, že boli bežným typom v sledovanom období a v regióne.

2. Súbor archeologických dát, z ktorého model vychádzal, sa ukázal ako nedostačujúci z viacerých hľadísk. Vďaka nízkemu počtu vstupných komponentov bolo vzájomné porovnávanie modelov veľmi nepriekazné. Presnosť datovania komponentov sa ukázala ako nedostačujúca. Rovnako ako samotná priestorová identifikácia komponentu (JASIEWICZ - HILDEBRANDT-RADKE 2009, 2099).
3. Dokazovanie signifikantnosti pomocou testu chi-kvadrát je závislé od rozdielu medzi pozorovanými a očakávanými výskytmi. V prípade, že sa v malej oblasti nachádza 10 komponentov a očakávaný počet je iba 1, rozdiel je teda 9, výsledná hodnota chi-kvadrátu bude 81. Naopak v oblasti s veľkou rozlohou a počtom pozorovaných komponent 59 a očakávaným počtom 50, bude chi-kvadrát iba 1.62 (VERHAGEN 2007, 59-60). Takže, v zásade záleží na veľkosti kategórií. To bol jeden z dôvodov prečo som sa snažil vyhnúť kategorizovaniu kontinuálnych premenných a test chi-kvadrát použil iba tam, kde to bolo nevyhnutné.
4. Náhodný výber, ktorým som rozdelil súbor archeologických dát na dva podsúbory (testovací a dizajnový) nezodpovedá potrebám priestorových analýz. Položky súboru boli síce náhodne roztriedené, ale bez ohľadu na ich priestorové usporiadanie. V budúcnosti by bolo dobré rozdeliť dáta tak, aby sa zamedzilo výberu komponentov tvoriacich zhľuky.

Záver

Témou diplomovej magisterskej práce bolo vytvorenie prediktívneho modelu včasno stredovekého osídlenia hornatých oblastí na severozápade Slovenska. Ťažisko práce leží v testovaní postupov prediktívneho modelovania za pomoci FUZZY logiky a štatistického overovania platnosti výsledkov.

Pri rekonštrukcii sídelnej štruktúry som vychádzal zo súboru lokalít publikovaného v práci P. Mila (2000). Tie boli pre účely prediktívneho modelovania transformované do podoby archeologických bodov (NEUSTUPNÝ 1986, 533). Vzniknutý súbor bol prostredníctvom náhodného výberu rozdelený na 2 skupiny. Prvá skupina (TEST SAMPLE) bola použitá pre externú validáciu vzniknutých modelov. Zatiaľ čo charakteristiky druhej skupiny (DESIGN SAMPLE) poslúžili k identifikácii trendov v osídlení regiónu.

Snažil som sa o vytvorenie čo najpresnejšieho modelu schopného predikovať výskyt archeologických areálov. Postup založený na prieniku booleanovských množín, kde je plocha buď vhodná alebo nevhodná (ÁNO/NIE; 1/0), som zamietol. Jeho striktné rozdelenie na zóny, by viedlo k zbytočnej kategorizácii premenných a ku strate informácii. Pri tvorbe modelu som sa pokúsil pracovať s vrstvami so spojitými premennými. Vzhľadom k povahe vstupných dát to nebolo možné pri dvoch vrstvách (FLORA, SOIL), ktorých hodnoty boli reprezentované kategorickou (nominálnou) premenou. Rozdielnosť formátov vstupných vrstiev si vyžiadala vypracovanie dvoch odlišných postupov overenia signifikantnosti ako aj pridelenia odlišných váh oblastiam s rôznou preferenciou.

Problémy spojené s predikciou archeologických areálov, ako boli predstavené v článku J. Jasiewicz a I. Hildebrandt-Radke (2009, 2096) som sa pokúsil vyriešiť za pomoci formalizovaných štatistických metód.

OTÁZKY²⁴:

1. Ako odhaliť premenné, ktoré majú vplyv na distribúciu komponentov. Je toto rozmiestnenie výsledkom reálnych preferencií vybraných faktorov?
2. Do akej miery tieto premenné ovplyvňujú štruktúru archeologický komponentov?
3. Ako identifikovať hranice oblastí predstavujúcich rôzne miery potenciálu?

²⁴ (JASIEWICZ - HILDEBRANDT-RADKE 2009, 2096)

Na vyriešenie otázky (1), či rozmiestnenie iba odráža lepšiu prístupnosť určitých oblastí, alebo výhodnosť socialno-ekonomických podmienok, som použil testy signifikantnosti. Pre výpočet miery ovplyvnenia distribúcie (2) archeologických komponentov jednotlivými premennými som použil upravené kritérium z práce J. Jasiewicza a I. Hildebrandt – Radke (2009, 2102). Počas riešenia otázky stanovenia hraníc kategórií potenciálu výskytu lokality (3) som využil optimalizáciu modelu z ohľadom na rôzne druhy jeho možného využitia. Použitím externého súboru dát (TEST SAMPLE) pri optimalizácii modelu som zároveň overil jeho výkon.

V závere práce som otestoval a overil výsledky rozdielnych postupov pri tvorbe prediktívnych modelov a platnosť hypotézy o štrukturujúcom vplyve blízkosti hradísk na osídlenie.

Na základe porovnania modelov M1²⁵ a M2²⁶ nemožno považovať pridelenie váh jednotlivým premenným použitých v práci za výrazne ovplyvňujúce výkon jednotlivých modelov.

Porovnaním modelov M3²⁷ a M4²⁸ som zistil, že výkon modelu M4 je výrazne lepší. Na základe čoho predpokladám, že blízkosť hradiska mala pozitívny vplyv pri výbere miesta pre osídlenie.

Každý z vytvorených prediktívnych modelov je možné považovať za úspešný. U obidvoch modelov je možné za pomoci optimalizácie dosiahnuť vhodných vlastností pre zamýšľaný účel použitia modelu. Za najväčší nedostatok modelov považujem slabo zastúpený súbor archeologických bodov. Tento je jednak nereprezentatívny z hľadiska priestorových vlastností a zároveň nepredstavuje chronologicky jednotný celok.

²⁵ Model M1 vznikol za predpokladu, že na štruktúru osídlenia vplývali všetky faktory rovnakou mierou.

²⁶ Model M2 vznikol kombináciou faktorov s prihliadnutím na rozdielnosť ich vplyvu.

²⁷ Model M3 predstavuje teóriu, v ktorej pri výbere polohy vhodnej pre osídlenie nebolo prihliadané na blízkosť centrálného sídliska. Pri tvorbe modelu do procedúry váženého prekryvu nebola zaradená vrstva časových vzdialeností od najbližšieho hradiska.

²⁸ Model M4 reprezentuje teóriu o vysokej atraktivite území vzdialených do dvoch hodín od centrálného sídliska.

Vzniknuté modely sú prvým formalizovaným krokom k poznaniu štruktúry osídlenia v sledovanom regióne. Rozdelenie modelov do dvoch kategórií dopomohlo k odhaleniu miest s vysokým potenciálom výskytu včasno stredovekých sídlisk. Kategória HIGH je jasne definovaná morfológiou terénu oblasti. Na otázku, či sa jedná o skutočný obraz sídelnej štruktúry, je možné odpovedať jedine za predpokladu existencie systematického prieskumu sledovaného regiónu. Slabé zastúpenie komponentov v oblasti Turčianskej kotliny či Turzovskej vrchoviny pravdepodobne reflektuje neexistenciu investigatívnych akcií v týchto oblastiach. Charakteristiky oboch oblastí indikujú zvýšený potenciál výskytu archeologických komponentov. Vytvorené indukívne modely, sú ovplyvnené stavom bádania a reprezentujú iba parciálne poznatky. K spresneniu modelov je nutné začleniť do analýz nové dáta získané z priestorovo rovnomerne zastúpených povrchových zberov. Pri týchto je potrebné pracovať nie len s pozitívnymi nálezmi, ale aj s informáciami o neexistencii indikátorov archeologických štruktúr. Kombináciou týchto informácií by bolo možné identifikovať miesta „bez nálezov“ a tieto overiť napríklad prostredníctvom mikrosondáží či povrchových zberov.

Prílohy

Model M1

VALUE	AREA (Km ²)	Count_Komp	Cum_P _s	Cum_P _a	R_gain	K_gain	K _i
2	0.13	0	1.000	1.000	0.000	0.000	0.000
3	1.26	0	1.000	1.000	0.000	0.000	0.004
4	5.33	0	1.000	1.000	0.000	0.000	0.013
5	12.78	0	1.000	0.999	0.001	0.001	0.028
6	22.01	0	1.000	0.998	0.002	0.002	0.048
7	33.99	0	1.000	0.995	0.005	0.005	0.070
8	54.08	0	1.000	0.991	0.009	0.009	0.094
9	81.21	0	1.000	0.985	0.015	0.015	0.124
10	107.77	0	1.000	0.975	0.025	0.025	0.159
11	130.37	0	1.000	0.963	0.037	0.037	0.196
12	150.08	0	1.000	0.948	0.052	0.052	0.235
13	170.08	0	1.000	0.930	0.070	0.070	0.274
14	190.04	0	1.000	0.911	0.089	0.089	0.313
15	224.91	0	1.000	0.888	0.112	0.112	0.354
16	283.48	0	1.000	0.862	0.138	0.138	0.400
17	260.62	0	1.000	0.829	0.171	0.171	0.454
18	214.89	0	1.000	0.799	0.201	0.201	0.501
19	183.77	0	1.000	0.774	0.226	0.226	0.540
20	176.50	1	1.000	0.753	0.247	0.247	0.573
21	177.96	0	0.978	0.732	0.246	0.251	0.564
22	184.15	1	0.978	0.712	0.266	0.272	0.596
23	195.96	0	0.956	0.690	0.265	0.278	0.588
24	209.74	0	0.956	0.667	0.288	0.302	0.622
25	221.00	1	0.956	0.643	0.313	0.327	0.659
26	222.45	0	0.933	0.617	0.316	0.339	0.657
27	217.99	0	0.933	0.591	0.342	0.366	0.696
28	213.76	0	0.933	0.566	0.367	0.394	0.736
29	217.84	0	0.933	0.541	0.392	0.420	0.776
30	239.74	0	0.933	0.516	0.417	0.447	0.818
31	223.03	0	0.933	0.488	0.445	0.477	0.866
32	177.17	1	0.933	0.462	0.471	0.505	0.912
33	141.66	0	0.911	0.441	0.470	0.515	0.898
34	128.98	2	0.911	0.425	0.486	0.534	0.928
35	122.30	0	0.867	0.410	0.457	0.527	0.854
36	118.90	0	0.867	0.396	0.471	0.543	0.878
37	118.80	1	0.867	0.382	0.485	0.559	0.903
38	124.63	1	0.844	0.368	0.476	0.564	0.876
39	124.53	1	0.822	0.354	0.469	0.570	0.851
40	118.79	0	0.800	0.339	0.461	0.576	0.827
41	110.22	0	0.800	0.325	0.475	0.593	0.850
42	104.41	0	0.800	0.313	0.487	0.609	0.872
43	101.05	0	0.800	0.300	0.500	0.625	0.894
44	105.28	0	0.800	0.289	0.511	0.639	0.915
45	97.50	0	0.800	0.276	0.524	0.654	0.938
46	89.05	1	0.800	0.265	0.535	0.669	0.959
47	83.67	2	0.778	0.255	0.523	0.673	0.924
48	84.48	1	0.733	0.245	0.488	0.666	0.837
49	83.91	0	0.711	0.235	0.476	0.669	0.804
50	82.43	1	0.711	0.225	0.486	0.683	0.819
51	81.28	0	0.689	0.216	0.473	0.687	0.786
52	80.79	0	0.689	0.206	0.483	0.700	0.801
53	77.95	0	0.689	0.197	0.492	0.714	0.817
54	73.71	0	0.689	0.188	0.501	0.727	0.832
55	69.05	0	0.689	0.179	0.510	0.740	0.846
56	66.48	1	0.689	0.171	0.518	0.751	0.860
57	62.12	0	0.667	0.164	0.503	0.755	0.822
58	61.87	0	0.667	0.156	0.510	0.765	0.833
59	58.41	0	0.667	0.149	0.517	0.776	0.846
60	57.19	1	0.667	0.142	0.524	0.786	0.857
61	54.31	0	0.644	0.136	0.509	0.789	0.817
62	52.18	0	0.644	0.129	0.515	0.799	0.827
63	49.90	2	0.644	0.123	0.521	0.809	0.837
64	50.27	0	0.600	0.118	0.482	0.804	0.748
65	59.46	1	0.600	0.112	0.488	0.814	0.757
66	47.51	1	0.578	0.105	0.473	0.819	0.720
67	44.00	3	0.556	0.099	0.456	0.821	0.683
68	44.71	3	0.489	0.094	0.395	0.807	0.565

VALUE	AREA (Km ²)	Count_Komp	Cum_P _s	Cum_P _a	R_gain	K_gain	K _i
69	42.11	0	0.422	0.089	0.333	0.789	0.459
70	43.47	2	0.422	0.084	0.338	0.801	0.464
71	40.96	0	0.378	0.079	0.299	0.791	0.401
72	39.48	1	0.378	0.074	0.304	0.803	0.406
73	38.73	0	0.356	0.070	0.286	0.804	0.377
74	43.28	1	0.356	0.065	0.290	0.817	0.381
75	36.90	3	0.333	0.060	0.273	0.820	0.354
76	34.98	3	0.267	0.056	0.211	0.791	0.267
77	36.97	1	0.200	0.052	0.148	0.741	0.187
78	45.16	0	0.178	0.047	0.130	0.733	0.163
79	35.92	1	0.178	0.042	0.136	0.763	0.167
80	43.22	1	0.156	0.038	0.118	0.755	0.144
81	25.61	1	0.133	0.033	0.100	0.752	0.122
82	23.89	1	0.111	0.030	0.081	0.730	0.099
83	21.32	1	0.089	0.027	0.062	0.693	0.076
84	23.02	1	0.067	0.025	0.042	0.628	0.054
85	20.54	0	0.044	0.022	0.022	0.503	0.032
86	19.21	1	0.044	0.020	0.025	0.556	0.034
87	15.41	0	0.022	0.017	0.005	0.213	0.010
88	18.96	0	0.022	0.016	0.007	0.294	0.012
89	17.26	0	0.022	0.013	0.009	0.393	0.014
90	13.39	0	0.022	0.011	0.011	0.483	0.016
91	17.12	1	0.022	0.010	0.012	0.553	0.017
92	33.05	0	0.000	0.008	-0.008		0.000
93	11.13	0	0.000	0.004	-0.004		0.000
94	12.24	0	0.000	0.003	-0.003		0.000
95	1.40	0	0.000	0.001	-0.001		0.000
96	1.65	0	0.000	0.001	-0.001		0.000
97	3.08	0	0.000	0.001	-0.001		0.000
98	4.36	0	0.000	0.001	-0.001		0.000
99	1.01	0	0.000	0.000	0.000		0.000
100	0.36	0	0.000	0.000	0.000		0.000

Tab. 48 – model M1

Model M2

VALUE	AREA (Km ²)	Count_Komp	Cum_P _s	Cum_P _a	R_gain	K_gain	K _i
2	0.32	0	1.000	1.000	0.000	0.000	0.000
3	2.72	0	1.000	1.000	0.000	0.000	0.006
4	9.40	0	1.000	1.000	0.000	0.000	0.019
5	19.24	0	1.000	0.999	0.001	0.001	0.038
6	30.96	0	1.000	0.996	0.004	0.004	0.061
7	50.57	0	1.000	0.993	0.007	0.007	0.086
8	81.92	0	1.000	0.987	0.013	0.013	0.115
9	115.94	0	1.000	0.977	0.023	0.023	0.152
10	146.17	0	1.000	0.964	0.036	0.036	0.194
11	170.59	0	1.000	0.947	0.053	0.053	0.237
12	196.00	0	1.000	0.927	0.073	0.073	0.281
13	235.58	0	1.000	0.904	0.096	0.096	0.325
14	284.63	0	1.000	0.877	0.123	0.123	0.375
15	267.79	0	1.000	0.844	0.156	0.156	0.430
16	239.38	0	1.000	0.813	0.187	0.187	0.480
17	210.30	0	1.000	0.785	0.215	0.215	0.524
18	200.05	1	1.000	0.760	0.240	0.240	0.561
19	203.61	0	0.978	0.737	0.241	0.246	0.557
20	216.66	1	0.978	0.713	0.264	0.270	0.593
21	225.82	0	0.956	0.688	0.267	0.280	0.591
22	230.40	0	0.956	0.662	0.294	0.307	0.630
23	234.17	1	0.956	0.635	0.320	0.335	0.671
24	232.16	0	0.933	0.608	0.325	0.349	0.671
25	236.96	0	0.933	0.581	0.352	0.378	0.713
26	244.96	0	0.933	0.553	0.380	0.407	0.756
27	231.45	0	0.933	0.525	0.408	0.438	0.803
28	201.24	1	0.933	0.498	0.435	0.466	0.848
29	169.52	0	0.911	0.475	0.437	0.479	0.840
30	154.91	0	0.911	0.455	0.456	0.501	0.874
31	153.33	2	0.911	0.437	0.474	0.520	0.907
32	143.91	0	0.867	0.419	0.448	0.516	0.838
33	133.12	1	0.867	0.402	0.464	0.536	0.867
34	118.36	1	0.844	0.387	0.458	0.542	0.844
35	110.20	0	0.822	0.373	0.449	0.546	0.819
36	106.56	0	0.822	0.360	0.462	0.562	0.840
37	102.09	0	0.822	0.348	0.474	0.577	0.861
38	99.39	0	0.822	0.336	0.486	0.591	0.882
39	97.02	1	0.822	0.324	0.498	0.605	0.903
40	96.36	0	0.800	0.313	0.487	0.609	0.871
41	93.19	0	0.800	0.302	0.498	0.623	0.891
42	92.10	0	0.800	0.291	0.509	0.636	0.910
43	95.16	1	0.800	0.280	0.520	0.649	0.930
44	88.97	0	0.778	0.269	0.508	0.654	0.897
45	83.16	0	0.778	0.259	0.519	0.667	0.916
46	77.12	1	0.778	0.249	0.528	0.679	0.934
47	74.36	2	0.756	0.240	0.515	0.682	0.896
48	74.63	1	0.711	0.232	0.479	0.674	0.809
49	72.86	0	0.689	0.223	0.466	0.676	0.775
50	69.82	0	0.689	0.215	0.474	0.688	0.788
51	67.36	0	0.689	0.206	0.482	0.700	0.801
52	66.70	0	0.689	0.199	0.490	0.712	0.814
53	64.96	0	0.689	0.191	0.498	0.723	0.827
54	63.65	1	0.689	0.183	0.506	0.734	0.839
55	62.37	0	0.667	0.176	0.491	0.736	0.801
56	59.97	0	0.667	0.169	0.498	0.747	0.813
57	56.75	0	0.667	0.162	0.505	0.757	0.825
58	55.12	1	0.667	0.155	0.512	0.767	0.836
59	53.86	0	0.644	0.149	0.496	0.769	0.796
60	52.65	0	0.644	0.142	0.502	0.779	0.806
61	48.30	0	0.644	0.136	0.508	0.788	0.816
62	48.28	0	0.644	0.131	0.514	0.797	0.825
63	47.33	1	0.644	0.125	0.519	0.806	0.834
64	44.15	1	0.622	0.120	0.503	0.808	0.793
65	41.27	1	0.600	0.114	0.486	0.809	0.753
66	42.32	2	0.578	0.110	0.468	0.810	0.713
67	41.72	2	0.533	0.105	0.429	0.804	0.632
68	42.04	1	0.489	0.100	0.389	0.796	0.558
69	37.41	3	0.467	0.095	0.372	0.796	0.525
70	55.01	0	0.400	0.091	0.309	0.773	0.423
71	41.04	2	0.400	0.084	0.316	0.789	0.430
72	41.79	1	0.356	0.079	0.276	0.776	0.368
73	36.94	1	0.333	0.075	0.259	0.776	0.341

VALUE	AREA (Km ²)	Count_Komp	Cum_P _s	Cum_P _a	R_gain	K_gain	K _i
74	37.59	0	0.311	0.070	0.241	0.774	0.314
75	41.46	3	0.311	0.066	0.245	0.788	0.318
76	41.15	2	0.244	0.061	0.183	0.750	0.234
77	32.88	1	0.200	0.056	0.144	0.718	0.183
78	34.41	1	0.178	0.053	0.125	0.705	0.160
79	37.96	1	0.156	0.049	0.107	0.688	0.137
80	45.42	2	0.133	0.044	0.089	0.669	0.114
81	29.38	0	0.089	0.039	0.050	0.563	0.068
82	44.96	0	0.089	0.035	0.053	0.602	0.071
83	27.52	1	0.089	0.030	0.059	0.660	0.074
84	28.07	1	0.067	0.027	0.040	0.595	0.052
85	20.25	0	0.044	0.024	0.021	0.466	0.031
86	17.50	0	0.044	0.021	0.023	0.519	0.032
87	21.56	1	0.044	0.019	0.025	0.565	0.034
88	23.75	0	0.022	0.017	0.005	0.242	0.011
89	14.65	0	0.022	0.014	0.008	0.367	0.014
90	14.69	0	0.022	0.012	0.010	0.443	0.015
91	17.39	0	0.022	0.011	0.012	0.520	0.016
92	28.91	1	0.022	0.009	0.014	0.611	0.017
93	18.26	0	0.000	0.005	-0.005		0.000
94	15.13	0	0.000	0.003	-0.003		0.000
95	1.85	0	0.000	0.001	-0.001		0.000
96	2.05	0	0.000	0.001	-0.001		0.000
97	4.52	0	0.000	0.001	-0.001		0.000
98	2.24	0	0.000	0.000	0.000		0.000
99	1.39	0	0.000	0.000	0.000		0.000

Tab. 49 – model M2

Model M3

VALUE	AREA (Km ²)	Count_Komp	Cum_P _s	Cum_P _a	R_gain	K_gain	K _j
2	0.23	0	1.000	1.000	0.000	0.000	#NUM!
3	2.15	0	1.000	1.000	0.000	0.000	0.005
4	10.68	0	1.000	1.000	0.000	0.000	0.017
5	27.09	0	1.000	0.998	0.002	0.002	0.039
6	47.58	1	1.000	0.995	0.005	0.005	0.068
7	70.80	0	0.978	0.990	-0.012	-0.012	#NUM!
8	104.52	0	0.978	0.982	-0.004	-0.004	#NUM!
9	154.08	1	0.978	0.969	0.008	0.009	0.091
10	203.73	0	0.956	0.952	0.004	0.004	0.062
11	241.03	0	0.956	0.928	0.028	0.029	0.165
12	269.07	0	0.956	0.900	0.056	0.058	0.238
13	293.60	0	0.956	0.869	0.087	0.091	0.302
14	320.28	0	0.956	0.834	0.121	0.127	0.363
15	368.36	0	0.956	0.797	0.158	0.166	0.424
16	448.24	0	0.956	0.754	0.201	0.211	0.491
17	406.83	0	0.956	0.702	0.253	0.265	0.569
18	338.16	0	0.956	0.655	0.301	0.315	0.641
19	250.64	1	0.956	0.616	0.340	0.356	0.702
20	195.85	0	0.933	0.586	0.347	0.372	0.704
21	171.12	0	0.933	0.564	0.370	0.396	0.740
22	169.02	1	0.933	0.544	0.390	0.417	0.772
23	164.61	0	0.911	0.524	0.387	0.425	0.758
24	155.92	1	0.911	0.505	0.406	0.446	0.789
25	144.85	1	0.889	0.487	0.402	0.452	0.773
26	135.59	1	0.867	0.470	0.397	0.458	0.755
27	128.55	0	0.844	0.454	0.390	0.462	0.735
28	124.67	0	0.844	0.439	0.405	0.480	0.758
29	123.63	0	0.844	0.425	0.420	0.497	0.781
30	119.25	1	0.844	0.410	0.434	0.514	0.805
31	113.14	0	0.822	0.397	0.426	0.518	0.781
32	107.96	0	0.822	0.383	0.439	0.534	0.802
33	104.07	0	0.822	0.371	0.451	0.549	0.822
34	105.02	1	0.822	0.359	0.463	0.564	0.843
35	123.28	0	0.800	0.347	0.453	0.567	0.815
36	111.58	0	0.800	0.332	0.468	0.585	0.839
37	102.37	0	0.800	0.319	0.481	0.601	0.861
38	89.87	0	0.800	0.307	0.493	0.616	0.881
39	78.92	3	0.800	0.297	0.503	0.629	0.900
40	75.14	0	0.733	0.288	0.446	0.608	0.768
41	77.64	1	0.733	0.279	0.454	0.620	0.781
42	73.99	0	0.711	0.270	0.441	0.620	0.749
43	70.78	0	0.711	0.261	0.450	0.632	0.762
44	68.68	1	0.711	0.253	0.458	0.644	0.775
45	68.16	0	0.689	0.245	0.444	0.644	0.741
46	70.24	0	0.689	0.237	0.452	0.656	0.753
47	66.76	1	0.689	0.229	0.460	0.668	0.766
48	66.17	0	0.667	0.221	0.445	0.668	0.732
49	63.93	0	0.667	0.214	0.453	0.680	0.743
50	60.99	0	0.667	0.206	0.460	0.691	0.754
51	58.14	0	0.667	0.199	0.468	0.701	0.765
52	56.15	0	0.667	0.192	0.474	0.712	0.776
53	55.52	1	0.667	0.186	0.481	0.721	0.786
54	56.87	0	0.644	0.179	0.465	0.722	0.749
55	56.78	0	0.644	0.173	0.472	0.732	0.759
56	54.64	0	0.644	0.166	0.478	0.742	0.769
57	52.89	0	0.644	0.160	0.485	0.752	0.779
58	50.76	0	0.644	0.154	0.491	0.762	0.788
59	49.50	2	0.644	0.148	0.497	0.771	0.798
60	49.64	1	0.600	0.142	0.458	0.763	0.712
61	47.13	2	0.578	0.136	0.442	0.764	0.676
62	45.94	1	0.533	0.131	0.403	0.755	0.600
63	46.48	0	0.511	0.125	0.386	0.755	0.567
64	44.19	0	0.511	0.120	0.391	0.765	0.573
65	41.06	1	0.511	0.115	0.396	0.775	0.579
66	42.23	1	0.489	0.110	0.379	0.775	0.546
67	41.59	2	0.467	0.105	0.362	0.775	0.514
68	40.56	1	0.422	0.100	0.322	0.762	0.448
69	37.03	1	0.400	0.096	0.304	0.761	0.418
70	36.79	1	0.378	0.091	0.286	0.758	0.389
71	39.94	0	0.356	0.087	0.269	0.755	0.361
72	42.07	1	0.356	0.082	0.273	0.768	0.366
73	36.66	5	0.333	0.077	0.256	0.768	0.339
74	29.43	0	0.222	0.073	0.149	0.671	0.197
75	35.53	3	0.222	0.070	0.152	0.686	0.200
76	35.26	0	0.156	0.066	0.090	0.578	0.124
77	40.91	2	0.156	0.062	0.094	0.604	0.127
78	33.59	0	0.111	0.057	0.054	0.489	0.080
79	28.73	0	0.111	0.053	0.058	0.524	0.083
80	70.97	1	0.111	0.050	0.062	0.554	0.085
81	32.24	0	0.089	0.041	0.048	0.535	0.067
82	32.57	0	0.089	0.038	0.051	0.577	0.069
83	24.58	0	0.089	0.034	0.055	0.620	0.072
84	19.39	1	0.089	0.031	0.058	0.652	0.074

VALUE	AREA (Km ²)	Count_Komp	Cum_P _s	Cum_P _a	R_gain	K_gain	K _i
85	23.81	0	0.067	0.029	0.038	0.570	0.051
86	30.72	2	0.067	0.026	0.041	0.612	0.053
87	26.84	0	0.022	0.022	0.000	-0.004	#NUM!
88	14.80	0	0.022	0.019	0.003	0.136	0.008
89	17.85	0	0.022	0.017	0.005	0.213	0.010
90	22.46	1	0.022	0.015	0.007	0.307	0.012
91	40.88	0	0.000	0.013	-0.013		0.000
92	25.84	0	0.000	0.008	-0.008		0.000
93	14.76	0	0.000	0.005	-0.005		0.000
94	16.24	0	0.000	0.003	-0.003		0.000
95	1.92	0	0.000	0.001	-0.001		0.000
96	2.43	0	0.000	0.001	-0.001		0.000
97	5.14	0	0.000	0.001	-0.001		0.000
98	1.18	0	0.000	0.000	0.000		0.000
99	1.63	0	0.000	0.000	0.000		0.000

Tab. 50 – model M3

Model M4

VALUE	AREA (Km ²)	Count_Komp	Cum_P _s	Cum_P _a	R_gain	K_gain	K _j
1	0.14	0	1.000	1.000	0.000	0.000	0.000
2	3.68	0	1.000	1.000	0.000	0.000	0.004
3	24.32	0	1.000	1.000	0.000	0.000	0.021
4	61.85	0	1.000	0.997	0.003	0.003	0.057
5	108.71	0	1.000	0.990	0.010	0.010	0.103
6	189.37	1	1.000	0.977	0.023	0.023	0.154
7	283.30	0	0.978	0.955	0.023	0.023	0.151
8	347.10	0	0.978	0.922	0.056	0.057	0.240
9	395.68	0	0.978	0.882	0.096	0.098	0.323
10	452.12	0	0.978	0.836	0.142	0.145	0.403
11	579.66	0	0.978	0.783	0.195	0.199	0.486
12	525.55	0	0.978	0.716	0.262	0.268	0.589
13	380.05	1	0.978	0.655	0.323	0.331	0.683
14	264.73	0	0.956	0.610	0.345	0.361	0.710
15	228.11	1	0.956	0.580	0.376	0.393	0.759
16	221.74	0	0.933	0.553	0.380	0.407	0.757
17	207.84	2	0.933	0.527	0.406	0.435	0.799
18	190.41	0	0.889	0.503	0.386	0.434	0.747
19	177.96	1	0.889	0.481	0.408	0.459	0.783
20	173.42	0	0.867	0.460	0.406	0.469	0.770
21	165.96	1	0.867	0.440	0.427	0.492	0.803
22	154.50	0	0.844	0.421	0.424	0.502	0.788
23	146.73	0	0.844	0.403	0.442	0.523	0.817
24	153.16	0	0.844	0.386	0.459	0.543	0.846
25	161.52	0	0.844	0.368	0.476	0.564	0.877
26	140.50	0	0.844	0.349	0.495	0.586	0.910
27	115.52	2	0.844	0.333	0.512	0.606	0.940
28	105.38	1	0.800	0.319	0.481	0.601	0.860
29	107.74	0	0.778	0.307	0.471	0.605	0.832
30	100.45	0	0.778	0.295	0.483	0.621	0.853
31	97.30	0	0.778	0.283	0.495	0.636	0.873
32	100.03	0	0.778	0.272	0.506	0.651	0.893
33	97.50	1	0.778	0.260	0.518	0.666	0.914
34	95.77	1	0.756	0.249	0.507	0.671	0.881
35	92.08	0	0.733	0.238	0.496	0.676	0.849
36	87.63	0	0.733	0.227	0.506	0.691	0.868
37	84.82	1	0.733	0.217	0.517	0.705	0.885
38	86.47	0	0.711	0.207	0.504	0.709	0.851
39	85.47	0	0.711	0.197	0.514	0.723	0.868
40	81.18	0	0.711	0.187	0.524	0.737	0.885
41	76.43	0	0.711	0.177	0.534	0.751	0.902
42	76.35	0	0.711	0.168	0.543	0.763	0.919
43	72.07	2	0.711	0.160	0.552	0.776	0.935
44	70.11	1	0.667	0.151	0.515	0.773	0.842
45	66.27	1	0.644	0.143	0.501	0.778	0.805
46	62.71	0	0.622	0.135	0.487	0.782	0.768
47	61.28	0	0.622	0.128	0.494	0.794	0.780
48	57.26	3	0.622	0.121	0.501	0.806	0.791
49	53.27	0	0.556	0.114	0.441	0.794	0.662
50	57.74	0	0.556	0.108	0.447	0.805	0.671
51	53.86	4	0.556	0.101	0.454	0.817	0.680
52	44.70	3	0.467	0.095	0.372	0.796	0.525
53	49.83	2	0.400	0.090	0.310	0.775	0.424
54	50.82	1	0.356	0.084	0.271	0.763	0.364
55	45.10	0	0.333	0.078	0.255	0.765	0.338
56	74.12	2	0.333	0.073	0.260	0.781	0.343
57	45.91	0	0.289	0.064	0.225	0.777	0.289
58	43.36	1	0.289	0.059	0.230	0.796	0.294
59	36.25	0	0.267	0.054	0.213	0.798	0.268
60	41.30	0	0.267	0.050	0.217	0.813	0.272
61	45.51	1	0.267	0.045	0.222	0.831	0.276
62	31.71	1	0.244	0.040	0.205	0.838	0.251
63	34.57	0	0.222	0.036	0.186	0.838	0.226
64	52.39	1	0.222	0.032	0.190	0.856	0.228
65	32.40	1	0.200	0.026	0.174	0.871	0.205
66	31.39	2	0.178	0.022	0.156	0.876	0.181
67	17.36	0	0.133	0.018	0.115	0.861	0.132
68	19.14	0	0.133	0.016	0.117	0.877	0.133
69	13.81	1	0.133	0.014	0.119	0.893	0.134
70	12.42	0	0.111	0.013	0.098	0.886	0.110
71	10.28	0	0.111	0.011	0.100	0.899	0.111
72	9.26	0	0.111	0.010	0.101	0.910	0.112

VALUE	AREA (Km ²)	Count_Komp	Cum_P _s	Cum_P _a	R_gain	K_gain	K _i
73	9.11	0	0.111	0.009	0.102	0.920	0.112
74	8.33	1	0.111	0.008	0.103	0.929	0.113
75	7.50	1	0.089	0.007	0.082	0.923	0.089
76	6.61	0	0.067	0.006	0.061	0.910	0.066
77	5.73	0	0.067	0.005	0.061	0.922	0.066
78	5.23	0	0.067	0.005	0.062	0.932	0.066
79	4.86	0	0.067	0.004	0.063	0.941	0.067
80	4.83	2	0.067	0.003	0.063	0.949	0.067
81	4.33	0	0.022	0.003	0.019	0.873	0.021
82	3.61	0	0.022	0.002	0.020	0.895	0.021
83	3.03	0	0.022	0.002	0.020	0.914	0.021
84	2.56	0	0.022	0.002	0.021	0.930	0.022
85	2.39	0	0.022	0.001	0.021	0.943	0.022
86	1.68	0	0.022	0.001	0.021	0.956	0.022
87	1.51	0	0.022	0.001	0.021	0.965	0.022
88	1.41	1	0.022	0.001	0.022	0.973	0.022
89	1.28	0	0.000	0.000	0.000		0.000
90	1.02	0	0.000	0.000	0.000		0.000
91	0.64	0	0.000	0.000	0.000		0.000
92	0.54	0	0.000	0.000	0.000		0.000
93	0.27	0	0.000	0.000	0.000		0.000
94	0.08	0	0.000	0.000	0.000		0.000

Tab. 51 – model M4

IdKomp	Obec	Ku	Poloha	Datovanie	KvDat	Rok	Badanie	ZachLok	RNDSEL	SI_PO	DruhNalezu	MODEL
30	Beluša		Laz pod Malenicou	8,9,11,12,	2	1963	PP	1	1	1	SI	1
35	Beluša		Pechová, Jarkový kút	včasný stredovek	3	1996	PP	1	1	1	SI	1
36	Beluša		Chrástky, Pod hájom	včasný stredovek	3	1996	PP	1	1	1	SI	1
43	Blatnica		Plešovica	9,10,	2	1974	PP	1	0	1	SI	1
53	Bojnice		Zadné lány	9,10,	1	1961	SV	1	1	1	SI	1
54	Bojnice		Vrábecké	9,10,	1	1961	SV	1	0	1	SI	1
55	Bojnice		Dolné lány	9,10,	1	1961	SV	1	0	1	SI	1
56	Bojnice		Lipiny	9	1	1961	SV	1	1	1	SI	1
57	Bojnice		Nemocnica	9,10,(zac)	1	1956	ZV	4	1	1	SI	1
62	Bojnice	Dubnica	Tále, parcela 1774	9,10,	1	1972	ZV	2	0	1	SI	1
70	Bolešov		V ohradách	9,12,13,	2	1962	PS	4	1	1	SI	1
73	Bolešov	Kamenicany	Luže, Podvrštie	slovanské obdob.	3	1996	PP	1	1	1	SI	1
93	Cernany		Podlužie	9,10,	2	1989	PP	1	0	1	SI	1
103	Diviacka Nová Ves		Za družstevným kravinom	9,10,	2	1996	ZV	1	0	1	SI	1
107	Diviaky nad Nitricou		Z. okraj obce medzi potokom a poln. cest.	10,11,12,	2	1975	PP	1	0	1	SI	1
113	Divinka		Ohrádza-Zábrehy	9,10,	2	1959	PP	1	0	1	SI	1
119	Dolná Mariková	Hatné	Záhradcie	9	2	1954	PP	1	1	1	SI	1
147	Gbelany		JZ.svahy na Z.okraji obce	9	2	1963	PP	1	0	1	SI	1
162	Horné Vestenice		Hôrka	9,10,	1	1942	ZiV	1	1	1	SI	1
190	Hricovské Podhradie		Hrad Hricov	9	2		PP	2	0	1	SI	1
201	Ilava		Poloha "pri píle"	9	2	1954	PP	1	0	1	SI	1
213	Ivanicná		Kratiny	9,(dr.pol.)	1	1962	SV	1	1	1	SI	1
215	Jablonové		Pri skale	9	2	1955	PP	1	0	1	SI	1
241	Jazernica		Pri rímsko katolíckom kostole	včasný stredovek	3	1955	PP	1	1	1	SI	1
264	Koš		100 m od parcely 3648	9	1	1970	NN	1	0	3	ON	1
265	Koš		Katkej kopec	9,10,11,	1	1963	SV	1	0	1	SI	1
268	Košeca	Nozdrovica	Tehelna	9,11,12, 13,	2	1950	PP	1	0	1	SI	1
269	Košecké Podhradie	Veľké Košecké Podhradie	Poloha "u mlyna"	8,9,	2	1955	PS	2	0	1	SI	1
273	Kralovany		Hradisko, úpätie	9	1		NN	3	1	3	ON	1
284	Kysucké N. Mesto	Radola	Pravý breh potoka Latyšev	9,10,11,	2		ZiV	1	1	1	SI	1
285	Kysucké N. Mesto	Radola	Záhlavci,L. breh potoka Latyšev	9,10, 11,12,(?)	3		PP	2	1	1	SI	1
287	Kysucké N. Mesto	Radola	Hradisko-Koscelisko	9,10, 11,12,13,	3	1959	ZV	1	0	1	SI	1
294	Lednica		Hrad	9	2	1953	PP	1	0	1	SI	1
373	Maršová		Na sedlišti	9,10,	2	1958	PS	2	1	1	SI	1
381	Martin	Košúty	Medzi cestou a polohou Hrádok	10,11,	2	1953	PS	3	1	1	SI	1
382	Martin	Košúty	Priehorie	9	1	1962	PS	3	0	1	SI	1
388	Martin	Záturcie	Medzi hradskou a riekou Turcom	10,11,	2	1953	PP	1	0	1	SI	1
399	Nedožery- Brezany	Brezany	Podcervenie	9,10,	1	1964	ZV	1	0	1	SI	1
401	Nedožery- Brezany	Nedožery	Sedlište	9,10,(pr .pol.)	2	1978	ZV	2	0	1	SI	1
418	Nitrianske Rudno		Horné Pažitie	9	2	1957	PP	1	0	1	SI	1
430	Nová Dubnica	Malý a Veľký Kolacín	Pod Huštíkom	9	2	1953	PP	1	0	1	SI	1
431	Nová Dubnica	Malý a Veľký Kolacín	Nádv. kaštie- la vo Veľkom Kolacíne	9	2	1953	PS	1	0	1	SI	1
435	Nováky		Štrkovisko 300 m.záp. od elrktárne	9,(?)	2	1960	NN	4	1	3	ON	1
445	Opatovce nad Nitrou		Bývalý Dobrotkov mlyn	9,(?)	3		NN	3	1	1	SI	1
454	Oslany		Horné lány 2	9,10,11, 12,13,14,	2	1989	PP	1	1	1	SI	1
487	Považská Bystrica		Dedovec	8,9,10,	1	1953	ZV	0	1	1	SI	1
488	Považská Bystrica		1,5 km JV od Dedovca, pri domoch	9,10,	3	1953	PP	1	1	3	ON	1
489	Považská Bystrica		Lány	9	2	1953	PP	1	1	1	SI	1

IdKomp	Obec	Ku	Poloha	Datovanie	KvDat	Rok	Badanie	ZachLok	RNDSEL	SI_PO	DruhNalezu	MODEL
493	Považská Bystrica	Považské Podhradie	Hradište	8,9,(?)	3	1953	PP	1	1	1	SI	1
496	Považská Bystrica	Sverepec	Lány	9,10,(?)	2	1957	PS	2	1	1	SI	1
499	Precín		Humenice	5,6,7,8,9,10,(?)	2	1960	ZiV	1	0	1	SI	1
506	Prievidza	Staré mesto	Námestie neďaleko piaristic. Kostola	9,12,	1	1936	ZiV	2	1	1	SI	1
507	Prievidza	Staré mesto	Pod Mariánskym vrškom	10,11,	2		PS	2	0	1	SI	1
508	Prievidza	Staré mesto	Mariánsky vršok	9,13,14,	1	1963	ZiV	1	1	1	SI	1
509	Prievidza	Staré mesto	Byvalá Ugróciho pieskovna	8,9,	3		NN	3	1	3	ON	1
511	Prievidza	Staré mesto	Mestský háj	9,10,(?)	3		PP	1	0	1	SI	1
514	Prievidza	Štvrte	Pod hradskou	10,11,	2	1962	SV	1	0	1	SI	1
522	Pruské	Vršatské Podhradie	Medziskalie	9, 10,(zac.)	1	1965	ZiV	0	1	3	DP	1
524	Pruské	Vršatské Podhradie	Hrad Vršatec	9, 10,(zac.)	1		NN	1	0	3	ON	1
525	Pruské	Vršatské Podhradie	Okolie chaty a kúpaliska pri zámku	9,10, 11,12,13,	2	1970	PP	1	1	1	SI	1
528	Pružina	Briestenné	kopec Mukovec	10,11,12,13,	2	1971	PP	1	1	1	SI	1
538	Púchov		Roh Ul. 1.mája a Obrán- cov mieru	9,10,	2	1956	NN	4	0	1	SI	1
539	Púchov		Hydináren pri Mäsokombináte	9,(pr.pol.)	1	1974	PS	4	1	1	SI	1
541	Púchov		Drahy pod Hôrkou	9	2	1969	PP	1	1	1	SI	1
542	Púchov		Breh Váhu pri moste	7,8,9,10,	2	1959	PP	2	1	1	SI	1
543	Púchov		Pod púchovskou Skalkou	8,9,	2	1979	PP	1	0	1	SI	1
545	Púchov	Dolné Kockovce	Rybničky	8,9,	2	1974	PS	3	0	1	SI	1
546	Púchov	Dolné Kockovce	Mociarne	9	2	1968	PS	3	0	1	SI	1
547	Púchov	Dolné Kockovce	Medzipotocie	9,12,13,	2	1968	PS	3	0	1	SI	1
549	Púchov	Horné Kockovce	Pod hrad	9,10,11,	2	1953	PP	3	0	1	SI	1
552	Rajecké Teplice		Skalky	9,10,11,	1	1954	ZiV	1	0	1	SI	1
564	Sklabina		SV. okraj obce, dom c.238 a 239	9	1	1958	NN	0	0	3	DP	1
685	Stránavy		Kubický vršok	10,11,12,	2	1963	NN	1	0	3	DP	1
688	Strecno		S.svah hradného vrchu	9,10,	1	1974	SV	1	0	1	SI	1
690	Sucany		Skala	9,10,11, 12,	2		PP	2	1	1	SI	1
692	Sucany		Medzi tehelnou a vrchom Skala	9,10,11, 12,	2	1954	PS	4	0	1	SI	1
709	Turčianske Klacany		Hrádok, Záhumnie	10,11,12,	2	1953	PP	2	1	1	SI	1
715	Udica	Malá Udica	Priehrada Mládeže	7,8,9,	2	1950	ZV	4	0	1	SI	1
739	Visolaje		Kultúrny dom	9,13,	2		PS	2	1	1	SI	1
769	Zemianske Kostolany		Štrkovisko	9	1	1965	ZV	4	1	1	SI	1
804	Žilina		Frambor	9,(dr.pol.)	1	1972	ZV	3	1	1	SI	1
805	Žilina		Pod Bôrikom	9	2	1962	PS	2	0	1	SI	1
807	Žilina		Šefranica	9,10,11	1	1962	PS	3	1	3	ON	1
809	Žilina	Bánová	Štrková terasa Rajcianky	9	2	1976	PS	2	1	1	SI	1
811	Žilina	Brodno	Sedlište	9	2	1981	PP	2	0	1	SI	1
812	Žilina	Porúbka	Dolina na ľavom brehu Rajcianky	9	2	1980	ZiV	1	1	1	SI	1
813	Žilina	Teplicka nad Váhom	Na vrškoch	10,11,	1	1969	ZV	3	0	1	SI	1
816	Žilina	Turie	Za hrádek	9,13,14,	2	1975	PP	1	1	1	SI	1
818	Žilina	Závodie	Pod vinicou	9	2	1993	PS	3	1	1	SI	1
819	Žilina	Závodie	Školská ulica	10,11,	1	1975	ZV	3	1	1	SI	1
820	Žilina	Závodie	Pod Stožkou	10,11,12,	2	1958	PS	3	1	1	SI	1

Tab. 52 – Súpis včasno stredovekých komponentov zo sledovaného regiónu.

IdKomp	Obec	Ku	Poloha	Datovanie
51	Bojnice		Zámok	9
112	Divinka		Veľký vrch	9,(dr.pol.), 10,(zac.)
188	Hričovské Podhradie		Mikov kopec	9,10,
237	Jasenovo		Vyšehrad	9,10, 13,14,15,
244	Kamenec pod Vtáčnikom		Hrádok	9
291	Ladce	Tunežice	Hradište	9
357	Lopušné Pažitie	Lopušná	Hrádok, vrch Malé Ostré	9,10,
366	Malá Cierna		Dubica	9
467	Podhradie		Erdegovo	9,10,(?)
513	Prievidza	Štvrte	Hradisko	8,(kon.), 9,(zac.),
581	Slovenské Pravno		Šiance	9,(kon.), 10
708	Turčianske Jasenovo	Horné Jasenovo	Hradište	10,11,12,
815	Žilina	Turie	Hrádek	9,10,
817	Žilina	Zástranie	Straník	10,11,12,

Tab. 53 – Súpis včasno stredovekých komponentov zo sledovaného regiónu označených ako hradisko.

IdKomp	Obec	Ku	DruhNalezu	RNDSEL	M2	M4
30	Beluša		SI	1	45	27
43	Blatnica		SI	0	31	16
70	Bolešov		SI	1	64	42
113	Divinka		SI	0	43	58
119	Dolná Mariková	Hatné	SI	1	40	31
162	Horné Vestenice		SI	1	47	29
190	Hricovské Podhradie		SI	0	18	19
215	Jablonové		SI	0	47	28
268	Košeca	Nozdrovice	SI	0	32	53
269	Košecké Podhradie	Veľké Koš. Podhradie	SI	0	48	33
273	Kralovany		ON	1	36	27
294	Lednica		SI	0	34	18
418	Nitrianske Rudno		SI	0	29	14
430	Nová Dubnica	Malý a Veľký Kolacín	SI	0	59	38
493	Považská Bystrica	Považské Podhradie	SI	1	20	11
496	Považská Bystrica	Sverepec	SI	1	41	24
499	Precín		SI	0	47	28
514	Prievidza	Štvrte	SI	0	23	48
522	Pruské	Vršatské Podhradie	DP	1	38	21
524	Pruské	Vršatské Podhradie	ON	0	20	7
525	Pruské	Vršatské Podhradie	SI	1	28	13
528	Pružina	Briestenné	SI	1	51	35
541	Púchov		SI	1	63	41
552	Rajecké Teplice		SI	0	33	18
685	Stránavy		DP	0	47	28
688	Strecno		SI	0	39	22
690	Sucany		SI	1	54	34
811	Žilina	Brodno	SI	0	54	34
812	Žilina	Porúbka	SI	1	41	57
816	Žilina	Turie	SI	1	41	61

Tab. 54 – Súpis včasno stredovekých komponentov zo sledovaného regiónu nachádzajúcich sa v oblasti s nízkym potenciálom výskytu arch. Komponentov.

Zoznam tabuliek, grafou a vyubrazení v texu

Graf 1 – Rozloženie kategórií rôznej kvality datovania v súbore archeologických komponentov.	28
Graf 2 – Zastúpenie jednotlivých druhov komponentov v rámci storočí.	31
Graf 3 – Odhad jadrovej hustoty pravdepodobnosti hodnôt vo vrstve LR150.	34
Graf 4 – Porovnanie odhadu jadrovej hustoty súborov BASPECT360 a BASPECT180.	36
Graf 5 – Porovnanie odhadu jadrovej hustoty vrstiev RBA180 (červená) a BRA180 (čierna).	40
Graf 6 – Odhad jadrovej hustoty pravdepodobnosti hodnôt z vrstvy SLOPE.	42
Graf 7 – Odhad jadrovej hustoty pravdepodobnosti hodnôt vo vrstve TCI.	45
Graf 8 – Odhad jadrovej hustoty pravdepodobnosti hodnôt vo vrstve TNIVA.	50
Graf 9 – Odhad jadrovej hustoty pravdepodobnosti hodnôt vo vrstve THRADISKA.	51
Graf 10 – Krabicový graf hodnôt časovej vzdialenosti od nív v súbore DESIGN SAMPLE.	69
Graf 11 – Krabicový graf hodnôt topografického pozičného indexu súboru DESIGN SAMPLE.	69
Graf 12 – Krabicový graf hodnôt svažitosti súboru DESIGN SAMPLE.	70
Graf 13 – Krabicový graf hodnôt relatívneho reliéfu súboru DESIGN SAMPLE.	70
Graf 14 – Histogram hodnôt v poli SLOPE.	78
Graf 15 – Odhad jadrovej hustoty pravdepodobnosti pre hodnoty v poli SLOPE.	78
Graf 16 – Histogram pre hodnoty v poli LR150.	80
Graf 17 – Odhad jadrovej hustoty pravdepodobnosti pre hodnoty v poli LR150.	80
Graf 18 – Histogram pre hodnoty v poli TCI.	83
Graf 19 – Odhad jadrovej hustoty pravdepodobnosti pre hodnoty v poli TCI.	83
Graf 20 – Histogram pre hodnoty v poli TNIVA.	84
Graf 21 – Odhad jadrovej hustoty pre hodnoty v poli TNIVA.	84
Graf 22 – Histogram pre hodnoty v poli THRADISKA.	86
Graf 23 – Odhad jadrovej hustoty pre hodnoty v poli THRADISKA.	86
Graf 24 – Zastúpenie jednotlivých kategórií v modeloch M3 a M4.	102
Graf 25 – Porovnanie zastúpenia kategórií v modeloch M3 a M4.	103
Graf 26 – Zastúpenie predikovaných komponentov v kategóriách v modeloch M3 a M4.	105
Graf 27 – Porovnanie zastúpenia kategórií v modeloch M2 a M4.	108
Graf 28 – Zastúpenie kategórií v modeli M2.	109
Graf 29 – Zastúpenie kategórií v modeli M4.	109
Graf 30 – Priebeh hodnôt gain pre model M2. Os x predstavuje hodnoty buniek v modeli M2.	111

Obr. 1 – Vymedzenie skúmanej oblasti v rámci územia Slovenska.....	4
Obr. 2 – Dislokácia geomorfologických útvarov na sledovanom území.....	5
Obr. 3 – Mapa podskupín pôdných typov v regióne (SOIL).	12
Obr. 4 – Rozmiestnenie hlavných vodných tokov v oblasti.....	14
Obr. 5 – Diagram postupou pri predikcii	20
Obr. 6 – Diagram pracovného postupu pri tvorbe modelu.	22
Obr. 7 – Mapa potenciálnej prirodzenej vegetácie na sledovanom území (FLORA).....	26
Obr. 8 – Prehľad komponentov v skúmanom regióne roztriedených podľa predpokladanej aktivity.	31
Obr. 9 – Postup pri aplikácii filtra v nástroji Focal Statistic (ESRI)	33
Obr. 10 – Vrstva lokálneho prevýšenia v kruhu 150m.....	34
Obr. 11 – Uhl'ová vzdialenosť od severného smeru.....	37
Obr. 12 – Postup pri tvorbe vrstvy RBA180.....	37
Obr. 13 – Postup pri tvorbe vrstvyBRA180.....	38
Obr. 14 – Vrstva svažitostí.	41
Obr. 15 – Model výpočtu vrstvy TCI (JENNESS a kol. 2010).	43
Obr. 16 – Vrstva potenciálneho zamokrenia oblasti.	44
Obr. 17 – Model výpočtu vrstvy TPI (JENNESS a kol. 2010).....	46
Obr. 18 – Charakterizácia hodnôt TPI (JENNESS a kol. 2010).	46
Obr. 19 – Vplyv veľkosti susedstva na hodnotu TPI (JENNESS a kol. 2010).....	47
Obr. 20 – Vrstva topografického pozičného indexu.....	47
Obr. 21 – Vrstva časovej vzdialenosti od nivných sedimentov.	49
Obr. 22 – Vrstva časovej vzdialenosti od najbližšieho hradiska.....	51
Obr. 23 – Hradiská v skúmanej oblasti. Popisok u bodu predstavuje hodnotu pola IdKomp zo súpisu hradísk (Tab. 53).....	52
Obr. 24 – Vrstva sídliskových archeologických komponentov.	64
Obr. 25 – Distribúcia komponentov patriacich do DESIGN SAMPLE.	66
Obr. 26 – Distribúcia komponentov patriacich do TEST SAMPLE.	66
Obr. 27 – Vrstva potenciálnej prirodzenej vegetácie po pridelení váh.....	77
Obr. 28 – Vrstva pôdných typov po pridelení váh.....	77
Obr. 29 – Vrstva svažitosti po pridelení váh.	79
Obr. 30 – Priebeh užívateľsky definovanej funkcie pre pridelenie váh vrstve LR150.....	81
Obr. 31 – Vrstva relatívneho prevýšenia v kruhu 150m po pridelení váh.	82
Obr. 32 – Vrstva potenciálneho zamokrenia oblasti po pridelení váh.	83
Obr. 33 – Vrstva časovej vzdialenosti od nivných sedimentov po pridelení váh.....	85
Obr. 34 – Vrstva časovej vzdialenosti od najbližšieho hradiska po pridelení váh.....	87
Obr. 35 – Rozdiel medzi termínom Acuraccy (správnosť) a Precision (presnosť).....	89
Obr. 36 – Model M1.....	95
Obr. 37 – Model M2.....	96
Obr. 38 – Model M3.....	98
Obr. 39 – Model M4.....	99

Obr. 40 – Vrstva časovej vzdialenosti od najbližšieho hradiska po pridelení váh podľa tabuľky 29.	100
Tab. 1 – Morfologické typy georeliéfu na sledovanom území. 6	
Tab. 2 – Test Chi-kvadrát zastúpenia archeologických komponentov v geomorfologických kategorióch.	7
Tab. 3 – Zastúpenie typov pôd v regióne.	11
Tab. 4 – Vegetačné stupne na území Slovenska (zdroj forestportal.sk).	16
Tab. 5 – Zastúpenie lesných typov v regióne.	17
Tab. 6 – Zastúpenie jednotlivých typov komponentov v rámci storočí. SI-sídliisko, PO – pohrebisko, INE- ostatné funkcie komponenty, HR – hradisko	28
Tab. 7 – Vzájomný vzťah medzi poľami kvalita datovania a badanie.	29
Tab. 8 – Zastúpenie spôsobov objavenia komponentu.	29
Tab. 9 – Zastúpenie spôsobov bádania v regióne Záhorie (TENCER 2008).	30
Tab. 10 – Rozloženie súboru komponentov v vrstve BASPECT360 a BASPECT180.	35
Tab. 11 – Výsledky testov normality súborov sampleRBA180 a sampleBRA180.	39
Tab. 12 – Výsledok porovnávania stredných hodnôt súborov sampleBRA180 a sampleRBA180. ...	39
Tab. 13 – Základné popisné charakteristiky premenných v spojitom formáte.	61
Tab. 14 – Váhy jednotlivých premenných.	62
Tab. 15 – Prehľad počtu komponentov v jednotlivých výberoch.	65
Tab. 16 – Výsledky testu chí-kvadrát vrstvy FLORA.	68
Tab. 17 – Výsledky testu chí-kvadrát vrstvy SOIL.	68
Tab. 18 – Prehľadné výsledky testov normality.	70
Tab. 19 – Výsledky testov normality.	71
Tab. 20 – Výsledky jednovzorkového t-testu.	72
Tab. 21 – Výsledky Wilcoxonovho znamienkového testu.	73
Tab. 22 – Výsledky jednovzorkového t-testu.	75
Tab. 23 – Váhy jednotlivých kategórií v premenných FLORA a SOIL.	76
Tab. 24 – Hodnoty definujúce priebeh užívateľskej funkcie pre vrstvu LR150.	81
Tab. 25 – Hraničné body definujúce priebeh funkcií použitých v module FUZZY.	86
Tab. 26 – Hraničné hodnoty kategórie s najvyšším potenciálom (HIGH).	93
Tab. 27 – Výsledky porovnávania modelu M1 a M2 optimalizovaných k vyššej miere ACCURACY..	95
Tab. 28 – Výsledky porovnávania modelov M1 a M2 optimalizovaných k vyššej miere PRECISION.	97
Tab. 29 – Hodnoty kontrolných bodov a typ funkcie zvolený pre výpočet vrstvy WTHRAD2H.	99
Tab. 30 – Hodnoty váh zvolené v procedúre MCE pri výpočte modelu M4.	101
Tab. 31 – Kritéria pre kategorizáciu modelov M3 a M4.	101
Tab. 32 – Hodnoty hraničných bodov a príslušné kumulatívne percentá pre jednotlivé kategórie.	102
Tab. 33 – Zmena zastúpenia kategórií v modeloch M3 a M4.	103
Tab. 34 – Zmena zastúpenia predikovaných komponentov v modeloch M3 a M4.	104
Tab. 35 – Hodnoty koeficientu zhody kappa v kategóriách medzi modelmi M3 a M4 (testuje sa celý raster).	104

Tab. 36 - Hodnoty koeficientu zhody kappa v kategóriách medzi modelmi M3 a M4 (testuje sa iba vrstva komponentov).	105
Tab. 37 - Zmena percentuálneho zastúpenia predikovaných komponentov v modeloch M3 a M4.	105
Tab. 38 – Výkon modelov M2, M3 a M4 s ACCURACY optimalizáciou.	106
Tab. 39 – Výkon modelov M2, M3 a M4 s optimalizáciou PRECISION.....	107
Tab. 40 – Porovnanie výkonov zón pre jednotlivé hraničné hodnoty v modely M2.	112
Tab. 41 – Výkon modelu M2 rozdeleného na zóny HIGH a LOW hodnotou 46.	113
Tab. 42 – Index významnosti pre optimalizované kategórie.	113
Tab. 43 – Prehľadné zobrazenie výsledkov optimalizácie modelu M2.	113
Tab. 44 - Porovnanie výkonu modelov M2 a M4 s precision optimalizáciou.	114
Tab. 45 – Porovnanie výkonu modelov M2 a M4 s accuracy optimalizáciou.	115
Tab. 46 – Prehľad výsledkov modelov M2 a M4.....	116
Tab. 47 – Zmena v kategorizácii komponent nachádzajúcich sa v zóne LOW v modely M2 alebo M4.	117
Tab. 48 – model M1	126
Tab. 49 – model M2	128
Tab. 50 – model M3	130
Tab. 51 – model M4	132
Tab. 52 – Súpis včasno stredovekých komponentov zo sledovaného regiónu.	134
Tab. 53 – Súpis včasno stredovekých komponentov zo sledovaného regiónu označených ako hradisko.	135
Tab. 54 – Súpis včasno stredovekých komponentov zo sledovaného regiónu nachádzajúcich sa v oblasti s nízkym potenciálom výskytu arch. Komponentov.....	135

Literatúra

AGROPORADENSTVO.SK. Fluvizeme.

<http://www.agroporadenstvo.sk/rv/poda/fluvizem.htm>

AGROPORADENSTVO.SK. Kambizeme.

<http://www.agroporadenstvo.sk/rv/poda/kambizem.htm>

AGROPORADENSTVO.SK. Redzina.

<http://www.agroporadenstvo.sk/rv/poda/rendzina.htm>

ANTALÍK, M. - BYSTRICKÁ, G. 2009: Geologické mapy na www.geology.sk, Príspevok prednesený na GIS Ostrava 2009.

BEČVÁŘ, L. 2007. Unitrans: Program na prevod mapových súradníc do formátu S-JTSK

BEVEN, K.J. - KIRKBY, M.J. 1979: A physically based, variable contributing area model of basin hydrology, Hydrologic Science Bulletin 24, 43-69.

BEYER, H.L. 2004. Hawth's Analysis Tools for ArcGIS

<http://www.spataleecology.com/htools>.

BIALEKOVÁ, D. 1992: Pramene k dejinám osídlenia Slovenska z konca 5. až 13. storočia. Nitra.

ČULÁKOVÁ, K. - OFÚKANÝ, M. 2003: Presnosť digitálneho modelu reliéfu územia PVOD Kočín, Pozemkové úpravy v podmienkách EU, Pedagogické listy 10.

DALLA BONA, L. 2003. Predictive Modelling Methodology.,

<http://modelling.pictographics.com/method.htm> [21.5.2011].

DANIELISOVÁ, B. 2008: Oppidum České Lhotice v kontextu svého sídelního zázemí. Univerzita Karlova v Praze, Praha.

DEEBEN, J. - HALLEWAS, D. a kol. 1997: Beyond the crystal ball: predictive modelling as a tool in archaeological heritage management and occupation history. In: Willems, W. (Ed.), Archaeological Heritage Management in the Netherlands. Fifty Years State Service for Archaeological Investigations, Leiden, 76-118.

DRENNAN, R.D. 2010: Statistics for Archaeologists: A Common Sense Approach. Oxford.

DRESLER, P. - MACHÁČEK, J. 2008: Hospodářské zázemí raně středověkého centra na Pohansku u Břeclavy. In: Macháček, J. (Ed.), Počítačová podpora v archeologii 2, Brno - Praha - Plzeň, 165-205.

EASTMAN, J.R. 2006. IDRISI Andes. Worcester, MA: Clark University

ESRI. 1999-2010. ArcGIS Help Library.

<http://help.arcgis.com/en/arcgisdesktop/10.0/help/index.htm> [10.5.2011].

ESRI. 2011. ArcGIS Desktop: Release 10. Redlands, CA: Environmental Systems Research Institute

FURMÁNEK, V. 1970: Výzkum ve Vršatskem Podhradí, Študijné Zvesti 18, 63-74.

- GEOLOGY.SK. 2010. Geologická mapa SR M 1 : 50 000.
http://www.geology.sk/?pg=geois.ms_gm50 [21.5.2011].
- GOLÁŇ, J. 2001: Archeologické prediktivní modelování pomocí geografických informačních systémů na příkladu území jihovýchodní Moravy. MU, Brno.
- GRAPHPAD. 2007a. GraphPad Prism version 5 for Windows. San Diego California USA: GraphPad Software www.graphpad.com.
- GRAPHPAD. 2007b. Online Quick Calculator - Grubbs test.
<http://www.graphpad.com/quickcalcs/Grubbs1.cfm> [20.5.2011].
- GRAPHPAD. 2007c: 18.4.2011. Online Quick Calculator - Kappa
<http://graphpad.com/quickcalcs/kappa1.cfm>
- GRAVES, D. 2010: The use of predictive modelling to target Neolithic settlement and occupation activity in mainland Scotland, Journal of Archaeological Science 38, 633-656.
- HENDL, J. 2006: Přehled statistických metod zpracování dat: Analýza a metaanalýza dat. Praha.
- HOBBS, E. - JOHNSON, C.M. a kol. 2002. Model development and evaluation.,
<http://www.mnmodel.dot.state.mn.us/chapters/chapter7.htm> [25.01.2011].
- HRNČÁROVÁ, T. 2002: Atlas krajiny Slovenskej republiky. Bratislava, Banská Bystrica.
- JASIEWICZ, J. - HILDEBRANDT-RADKE, I. 2009: Using multivariate statistics and fuzzy logic system to analyse settlement preferences in lowland areas of the temperate zone: an example from the Polish Lowlands, Journal of Archaeological Science 36, 2096-2107.
- JENNESS, J. 2010. Topographic convergence index
<http://www.jennessent.com/arcview/tpi.htm>.
- KAMERMANS, H. - LEUSEN, M. a kol. 2009: Archaeological prediction and risk management, alternatives to current practice. Leiden.
- KOPECKÝ, M. - ČÍŽKOVÁ, Š. 2010: Using topographic wetness index in vegetation ecology: does the algorithm matter?, Applied Vegetation Science 13, 450-459.
- KRIPPEL, E. 1986: Postglaciálny vývoj vegetácie Slovenska. Bratislava.
- KUNA, M. 1996: GIS v archeologickém výzkumu regionu: Vývoj pravěké sídelní oblasti středních čech, Archeologické rozhledy 46, 586.
- KUNA, M. 2004: Nedestruktivní archeologie. Praha.
- KUNA, M. 2006: Burial mounds in the landscape. In: Šmejda, L. (Ed.), Archaeology of Burial Mounds, Plzeň, 83-97.
- KUNA, M. 2008: Analýza polohy pravěkých mohylových pohřebišť pomocí geografických informačních systémů. In: Macháček, J. (Ed.), Počítačová podpora v archeologii 2, Brno - Praha - Plzeň, 79-93.

- KVAMME, K., L. 1990: One-sample tests in regional archaeological analyses: New possibilities through computer technology., *American Antiquity* 55, 367-381.
- KVAMME, K.L. 1988: Development and testing of quantitative models. In: JUDGE, J.W.a.S., L. (Ed.), *Quantifying the Present and Predicting the Past: Theory, Method, and Application of Archaeological Predictive Modeling*, Denver, 325-428.
- LLOBERA, M. 2000: Understanding movement: a pilot model towards the sociology of movement. In: Lock, G. (Ed.), *Beyond the map. Archaeology and spatial technologies*, Amsterdam - Berlin - Oxford - Tokyo - Washington DC., 65 - 84.
- LLOBERA, M. 2001: Building Past Landscape Perception With GIS: Understanding Topographic Prominence, *Journal of Archaeological Science* 28, 1005-1014.
- LUKNIŠ, M. - MAZÚR, E. 1986: Geomorfologické členenie SSR a ČSSR. Časť Slovensko. Bratislava.
- MACHÁČEK, J. 2001: Studie k velkomoravské keramice. Metody, analýzy a syntézy, modely. Brno.
- MELOUN, M. - MILITKÝ, J. 2002: Kompendium statistického zpracování dat. Praha.
- MICROSOFT. 2002. Office 2003: Microsoft www.office.microsoft.com.
- MILO, P. 2000: Vývoj a štruktúra stredovekého osídlenia v hornatých oblastiach Slovenska. UKF, Nitra.
- MORAVČÍK, J. 1976: Najnovšie archeologické nálezy z Púchova a okolia, *Vlastiv. Zborník Považia* 12-49.
- MORAVČÍK, J. 1995: Nové poznatky o osídlení hradu Hričov, *AVANS* v roku 1993 96-97.
- NEŠPOROVÁ. 1986: Prírastky archeologických nálezov v Trenčianskom múzeu, *AVANS* v roku 1985 163-167.
- NEUSTUPNÝ, E. 1986: Nástin archeologické metody., *AR* 38, 525-549.
- NEUSTUPNÝ, E. 2000: Predikce areálů archeologického zájmu, *Památky Archeologické supplementum* 13, 319-324.
- NEUSTUPNÝ, E. 2006: Syntéza struktur formalizovanými metodami - Vektorová syntéza. In: Neustupný, E. - John, J. (Eds.), *Příspěvky k archeologii* 2, Plzeň.
- NEUSTUPNÝ, E. 2007: Metoda archeologie. Plzeň.
- NOVÁK, V. 2000: Základy fuzzy modelování. Praha.
- OCHRANA, F. 2009: Metodologie vědy: Úvod do problému. Praha.
- PAULÍNY, J. 1999: Arabské správy o Slovanoch. (9.- 12. storočie). Bratislava.
- PAVLICA, V. - ČERVINKA, V. a kol. 1958: Studium a stanovení mezí přesnosti topografických map měřítka 1:25000, *Vojenský topografický obzor (VTO)*, Sborník MNO 1.

- PETROVSKÝ-ŠICHMAN, A. 1964a: Slovanské lokality v Žilinskej kotline, Študijné Zvesti 14, 175-186.
- PETROVSKÝ-ŠICHMAN, A. 1964b: Slovanské osídlenie severného Slovenska, Vlastiv. Zborník Považia 6, 50-106.
- POPPER, K.P. 1997: Logika vědeckého zkoumání Praha.
- RADĚJ, K. 2001. První celostátní topografické mapování v měřítku 1 : 25 000. <http://www.zememeric.cz/5-01/mapovani.html> [28.3.2011].
- RIMARČÍK, M. 2008. Štatistický navigátor. www.rimarcik.com [20.5.2011].
- ROBINSON, B.V. 2009: Fuzzy Sets in Spatial Analysis. In: Fotheringham, A.S. - Rogerson, P. (Eds.), The SAGE handbook of spatial analysis, Los Angeles; London; New Delhi [etc.].
- RUTTKAY, A. 1965: Nové nálezy z Horného Ponitra, Študijné Zvesti 15, 189-214.
- RUTTKAY, A. 1966: Osídlenie hornej Nitry na zlome letopočtu, Horná Nitra 3, 7-25.
- ŠMEJDA, L. 2003: Možnosti využití techniky "Multi-Criteria Evalution" v prostorové archeologii In: Neustupný, E. (Ed.), Příspěvky k prostorové archeologii 1, Plzeň.
- STATSOFT. 2010. STATISTICA version 9.1. Tulsa, OK, USA: Statsoft, Inc. www.statsoft.com.
- TEAM, R.D.C. 2010. R: A language and environment for statistical computing. Vienna, Austria: R Foundation for Statistical Computing R-project.org.
- TENCER, T. 2008: Geografické a archeologické priestorové dáta z územia Slovenska. In: Macháček, J. (Ed.), Počítačová podpora v archeologii 2, Brno - Praha - Plzeň, 262-287.
- TRIPCEVICH, N. 2004. ArcGIS Desktop Discussion Forums: Anisotropic hiking speed functions. <http://forums.esri.com/Thread.asp?c=93&f=995&t=138683&mc=10#415008> [21.5.2011].
- VAŠKOVÝCH, I. 1977: Kvartér Slovenska. Bratislava.
- VERHAGEN, P. 2007: Case studies in archaeological predictive modeling. Leiden.
- VERHAGEN, P. 2009: Testing archaeological predictive models: a rough guide. In: Kamermans, H., Leusen, M. - Verhagen, P. (Eds.), Archaeological prediction and risk management, alternatives to current practice, Leiden, 63-70.
- VLACH, M. 2010: Žárové pohřebiště v Šitbořicích a přilehlý region v době římské., Brno.
- WANSLEEBEN, M. - VERHART, L.B.M. 1992: The Meuse Valley Project: GIS and site location statistics, Analecta Praehistorica Leidensia 25, 99-108.
- WEISS. 2001: Topographic Position and Landforms Analysis, Príspevok prednesený na ESRI User Conference.

- WHITLEY, T., G. 2005: A Brief Outline of Causality-Based Cognitive Archaeological Probabilistic Modeling. In: van Leusen, M. - Kamermans, H. (Eds.), Predictive Modelling for Archaeological Heritage Management: A research agenda. Nederlandse Archeologische Rapporten 29, 123-137.
- WIKIPEDIA.ORG. 2011a. Hydrologické poradie na Slovensku. http://sk.wikipedia.org/wiki/Hydrologick%C3%A9_poradie_na_Slovensku [20.5.2011].
- WIKIPEDIA.ORG. 2011b. Rieka Kysuca. <http://sk.wikipedia.org/wiki/Kysuca> [20.5.2011].
- WIKIPEDIA.ORG. 2011c. Rieka Nitra. [http://sk.wikipedia.org/wiki/Nitra_\(rieka\)](http://sk.wikipedia.org/wiki/Nitra_(rieka)) [21.5.2011].
- ZADEH, L.A. 1965: Fuzzy Sets, Information and Control 8, 338-353.

