

**Ing. Martina Dekanová**

**Autoreferát dizertačnej práce**

## **Automatizovaná predikcia lavínového nebezpečenstva**

**na získanie akademického titulu**

philosophiae doctor“, v skratke „PhD.“

**v doktorandskom študijnom programe:** Robotika a kybernetika

**v študijnom odbore:** 9.2.7. kybernetika

**Forma štúdia:** Denná

**Miesto a datum:** Bratislava 4. 12. 2019

**Dizertačná práca bola vypracovaná na** Ústave robotiky a kybernetiky  
Fakulty elektrotechniky a informatiky  
Slovenskej technickej univerzity v Bratislave

**Predkladateľ** Ing. Martina Dekanová  
FEI STU Bratislava, ÚRK

**Školiteľ** prof. Ing. František Duchoň, PhD.  
FEI STU Bratislava, ÚRK

**Oponenti** Mgr. Pavel Krajčí, PhD.  
Horská záchranná služba, stredisko lavínovej  
prevencie  
Liptovský Hrádok

Doc. Ing. Dušan Koniar, PhD.  
EF ŽU Žilina, KME

**Autoreferát bol rozoslaný dňa**

**Obhajoba dizertačnej práce sa bude konať dňa 23. 1. 2020 o 10<sup>00</sup> v D424 na FEI STU**

prof. Dr. Ing. Miloš Oravec  
Dekan FEI STU

# Obsah

Úvod .....	4
1. Tézny dizertačnej práce .....	5
2. Lavíny .....	5
2.1. Definície základných pojmov .....	5
2.2. Typy lavín .....	5
2.3. Faktory vzniku lavín .....	6
2.4. Popis oblasti .....	7
2.4.1. Automatické meteorologické stanice .....	7
3. Návrh realizácie práce .....	8
4. Riešenie vypadnutých údajov .....	8
4.1. Výpadok údajov do 1 hodiny (1 údaj) .....	10
4.2. Výpadok údajov nad 1 hodinu .....	10
5. Spracovanie pre neurónovú sieť .....	11
5.1. Teplota vzduchu .....	11
5.2. Výška snehu .....	12
5.3. Slnéčné žiarenie a radiácia .....	13
5.4. Zrážky a relatívna vlhkosť .....	14
5.5. Rýchlosť a smer vetra .....	14
5.6. Teplota v snehu .....	15
6. Neurónová sieť .....	15
6.1. Nastavenie neurónových sietí .....	15
7. Zhodnotenie výsledkov - neurónové siete .....	16
7.1. Porovnanie navrhnutých sád .....	17
7.2. Zhodnotenie podľa vrstiev .....	18
7.3. Zhodnotenie podľa učiacej funkcie .....	18
7.4. Zhodnotenie údajov z Wattener Lizum .....	19
Záver .....	22
LITERATÚRA .....	24

# ÚVOD

V posledných rokoch narástol počet ľudí, ktorí trávia čas pri rekreačných činnostiach ako je lyžovanie, či turistika v zimných horách. V zimnej sezóne 2007/2008 bolo zaznamenaných 193 lavín, pri ktorých bolo strhnutých alebo ohrozených 19 osôb, pričom k následkom smrti došlo len v jednom prípade u 2 osôb. V zimnej sezóne 2016/2017 bolo ohrozených 28 osôb, pričom bolo v lavíne strhnutých až 22 osôb. [1] [2] [3]

Všeobecný zvyšujúci sa trend športovania vo voľnom zimnom teréne prináša vyššie riziko vzniku lavín a ohrozenia na životoch. Keďže už pohyb v zimnom teréne nepatrí len skúseným športovcom a profesionálom, ale aj bežným rekreačným športovcom, tak stúpa potreba zvyšovania edukácie o rizikách, ktoré sú spájané s pohybom v zimnom teréne. Aj z tohto dôvodu narastá dôležitosť určovania stupňa lavínového nebezpečenstva. V súčasnosti sa stupeň lavínového nebezpečenstva na Slovensku určuje pre celé pohorie. Aktuálne je určovaný stupeň samostatne pre Vysoké Tatry, Západné Tatry, Nízke Tatry, Malú Fatru a Veľkú Fatru. Nevýhodou takéhoto určovania je, že tento stupeň nereprezentuje rovnaké nebezpečenstvo pre každú časť určovaného pohoria. V ideálnom prípade by sa mal stupeň lavínového nebezpečenstva určovať pre jednotlivé doliny v pohoriach. K tomu je potrebné zabezpečiť hustejšiu sieť staníc, ktoré zabezpečujú meranie informácií o snehu a počasí ako aj zefektívniť určovanie stupňa lavínového nebezpečenstva expertom.

Štatistiky a štúdie venované lavínovým nebezpečenstvám na Slovensku ako aj vo svete ukazujú, že dôvodom vytvorenia väčšiny lavín sú práve tie osoby, ktoré v týchto lavínach zomreli alebo boli zranené. Častejšie sú za odtrhom lavíny skialpinisti a snowboardisti, kým peší turisti zväčša nie sú obeťami lavín. Pri dokumentácii lavínovej nehody sa vo veľa prípadoch príde na to, že tejto nehode bolo možné zabrániť, ak by pred vstupom do terénu boli overené aktuálne podmienky v horách.

V súčasnosti stupeň lavínového nebezpečenstva určujú experti, ktorí využívajú rôzne počítačové aplikácie na spracovanie údajov a vizualizovanie ich priebehov. Taktiež sa začínajú využívať aj nástroje na analýzu údajov, ktoré majú pomôcť expertom zefektívniť prácu. Pri týchto analýzach je dôležité nastavenie parametrov tak, aby vhodne reprezentovali sledovanú oblasť. Každá oblasť má svoje špecifické vlastnosti (sklon svahu, orientácia,...), ktoré je nutné v analýzach brať do úvahy. Väčšina existujúcich modelov predpovedania lavínového nebezpečenstva dokáže predikovať len samovoľne vytvorené lavíny, pričom sa využívajú hlavne meteorologické údaje a údaje o snehu. Lavíny, ktoré sú spôsobené umelo (lyžiar, zver,...), sa predikujú náročnejšie, keďže pohyb človeka alebo zvierat'a nie je možné do predpovede zahrnúť, keďže tento pohyb nie je známy. [4]

# 1. Tézzy dizertačnej práce

Základné tézy dizertačnej práce sú:

- Navrhnuť automatické doplnenie údajov v neplatných meraniach AMS.
- Verifikovať navrhnuté riešenie na reálnych údajoch.
- Navrhnuť funkcie predspracovania nameraných údajov pre predikciu lavínového nebezpečenstva.
- Na reálnych údajoch overiť navrhnuté predspracovanie napr. pomocou neurónových sietí.
- Overiť navrhnuté riešenie predikcie lavínového nebezpečenstva pre rôzne oblasti.

## 2. Lavíny

### 2.1. Definície základných pojmov

V úvode je potrebné zdefinovať dva základné pojmy ohľadne lavínovej problematiky a to [5] [6]:

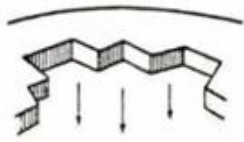
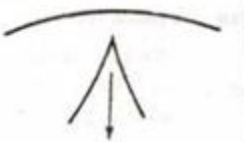



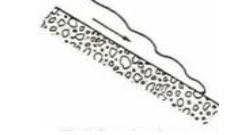
- **Splaz** je zosunutie malej vrstvy snehu pomalou rýchlosťou. Zvyčajne je dráha splazu kratšia ako 50 metrov. Splaz by sa dal opisne prirovnať k stekaniu hustej tekutiny.
- **Lavína** na rozdiel od splazu je rýchly zosuv vrstvy alebo vrstiev snehu, zvyčajne na strmších svahoch. Každá lavína začína odtrhom (miesto, kde sa lavína uvoľnila) pokračuje transportným pásmom (dráha kadiaľ lavína tiekla) a končí v nánosovom pásme.

Lavíny na rozdiel od splazov majú výrazne vyššie riziko ohrozenia života, majetku, či lesa. Aj z tohto dôvodu sa táto práca venuje riziku vzniku lavín.

### 2.2. Typy lavín

Existuje niekoľko typov klasifikácií lavín. Najčastejšie používané klasifikácie sú uvedené v tabuľke 2.1, v ktorej je definované podľa čoho sa lavíny klasifikujú a k názvom je znázornený aj ilustračný obrázok, aby priblížil rozdiel v lavínach. [5] [4] [7]

Tabuľka 2.1 Typy klasifikácie lavín [5]

Typ klasifikácie	Typ lavíny	
<b>Tvar odtrhu</b>	<p>Čiarový odtrh (dosková lavína)</p> 	<p>Bodový odtrh (lavína z voľného snehu)</p> 
<b>Poloha klznej plochy</b>	<p>Vnútri snehovej pokrývky (povrchová lavína)</p> 	<p>Na pôde (základová lavína)</p> 
<b>Vlhkosť snehu</b>	Suchý	Mokrý
<b>Tvar dráhy – priečny profil</b>	Plošná lavína	Žľabová lavína
<b>Forma pohybu</b>	Turbulentný (prachová lavína)	Kĺzavý, tečúci (tečúca lavína)
		

### 2.3. Faktory vzniku lavín

Vznik lavíny je závislý od viacerých faktorov ako je napr. sklon svahu, orientácia svahu, teplota vzduchu, stabilita snehových vrstiev. Tieto faktory sa dajú rozdeliť do dvoch skupín a to meteorologické faktory, ktoré sa v čase menia a topografické faktory, ktoré sú v čase nemenné. Medzi meteorologické faktory sa zaraďujú sila a smer vetra, sneh, zrážky, vlhkosť prostredia, vlhkosť snehu, teplota ovzdušia, teplota v snehu a ďalšie informácie o snehu. Medzi topografické faktory sa zaraďuje sklon svahu, porast, povrch svahu a ďalšie faktory. V ďalšej časti budú v krátkosti zhrnuté vlastnosti a vplyv niektorých meteorologických faktorov na vznik lavín., S nimi sa pracuje aj pri algoritme na predikciu lavínového nebezpečenstva, ktorému sa táto práca venuje. [5] [4] [7] [8]

V [9] sa zaoberali ďalšími parametrami a ich vplyvom na vznik lavín. Sledovali vplyv teploty pôdy 10 cm pod povrchom, množstvo vody v snehovej pokrývke ako aj vplyv machov ako porastu na vznik lavín. Tieto parametre však nie sú merané v oblastiach, v ktorých sa táto práca realizovala.

## 2.4. Popis oblasti

V tejto práci sú testy vykonávané v dvoch rôznych oblastiach. Prvá oblasť je v Západných Tatrách, kde sú k dispozícii merania z troch automatických meteorologických staníc (AMS alebo AWS), kde jedna stanica obsahuje len informácie o teplote a vetre. Ďalšie dve stanice sú umiestnené pri Žiarskej chate a na Hrubej Kope. Lavínový stupeň sa momentálne určuje pre celú oblasť Západných Tatier ako celok. Druhá oblasť sa nachádza v Rakúsku, Tirolsku v oblasti Wattener Lizum. Pre túto oblasť je k dispozícii 1 meteorologická stanica a lavínový stupeň sa určuje len pre okolie tejto stanice.

### 2.4.1. Automatické meteorologické stanice

AMS stanice v Západných Tatrách sú od spoločnosti Microstep-MIS. V tejto práci sa pracuje hlavne s údajmi z meteorologických staníc na Žiarskej chate. AMS na Žiarskej chate je umiestnená vo výške 1285 m.n.m. a jej súčasťou je aj webkamera. Do roku 2015 posielali tieto AMS údaje každých 60 minút a od roku 2015 je tento interval zvýšený a posielajú sa údaje každých 10 minút, pričom snímky z webkamery ostávajú v predchádzajúcom intervale, teda 60 minútovom.

AMS v rakúskej oblasti Wattener Lizum je umiestnená vo výške 2040 m.n.m., kde je zároveň umiestnený aj laserový skener, ktorý je možné ovládať na diaľku. V stanici je meraná teplota vzduchu, relatívna vlhkosť, rýchlosť a smer vetra, výška snehu, žiarenie, teplota snímača. Existujúce metódy identifikácie stupňa lavínového nebezpečenstva

V praxi už existuje niekoľko riešení, ktoré pomáhajú určovať lavínové nebezpečenstvo automatizovane alebo poloautomatizovane. Zatiaľ neexistuje žiadny systém, ktorý by mohol fungovať úplne samostatne a zverejňovať lavínové hrozby bez kontroly expertom. No aj systém, ktorý expertom urýchli určovanie lavínového nebezpečenstva je v praxi veľmi užitočný.

Existujú dva základné typy systémov. Jeden je systém, ktorý určuje, či lavína v danej oblasti padne alebo nie, prípadne s akou pravdepodobnosťou a druhý typ systémov je, že určujú stupeň lavínového nebezpečenstva pre určovanú oblasť. Prvý typ systémov sa používa hlavne v oblastiach, kde je výskyt lavín vysoký (viac ako 30% dní zo sledovaného obdobia bolo lavínových, teda v daný deň padla aspoň jedna lavína). Druhý typ sa naopak používa hlavne v turistických oblastiach a v oblastiach, kde vzniká menej prirodzených lavín a častejšie sú spôsobené človekom.

Ďalej sa tieto systémy rozlišujú na akom základe boli vytvorené. Častými metódami, ktoré sa používajú sú mnohé štatistické metódy ako napríklad metódy klasifikačných stromov, metóda najbližšieho suseda, neurónové siete alebo strojové učenia. Niektorým metódam sa venujú ďalšie časti tejto práce. Ďalšie štatistické metódy je možné nájsť napríklad v [10], [11] a [12].

### 3. Návrh realizácie práce

Nasledujúce kapitoly sa venujú návrhu a realizácii riešenia pre systém predikcie lavínového nebezpečenstva pre údaje zo Západných Tatier (Horská záchranná služba, Slovensko) a pre údaje z Wattener Lizum (Inštitútu pre prírodné hrozby, Rakúsko).

AMS v Západných Tatrách obsahujú 45 meteorologických údajov a údajov o snehu. Tak ako nie sú schopní experti pri určovaní lavínového stupňa sledovať všetkých 45 meraných údajov, tak sa nedokázala ani umelá inteligencia naučiť dostatočne správne určovať lavínové nebezpečenstvo zo všetkých údajov. Pričom niektoré údaje majú príliš veľkú nepresnosť vzhľadom na nepresnosť snímača (napr. teplota na povrchu snehu) ako aj tým, že tento údaj reálne nie je meraný (napr. teplota v snehu, kedy výška snehu je nižšia ako je poloha snímača teploty). Aj z týchto dôvodov je dôležité vybrať také namerané údaje, ktoré majú výrazný vplyv na lavínové nebezpečenstvo. Zároveň pri niektorých parametroch má vplyv na lavínové nebezpečenstvo zmena v čase, ktorá je podľa parametrov rôzna. Z uvedených dôvodov je nutné vykonať predspracovanie týchto údajov predtým ako vstupujú napr. do neurónovej siete.

Pre vytvorený algoritmus predikovania lavínového nebezpečenstva v tejto práci boli vybrané merané údaje, s ktorými sa bude pracovať. Z údajov zo Západných Tatier sa pracuje s výškou snehu, dĺžkou slnečného žiarenia, radiáciou, zrážkami, relatívnou vlhkosťou, teplotou vzduchu, rýchlosťou a smerom vetra a teplotou v snehu (podľa výšky snehu). Pre stanicu vo Wattener Lizum sa pracuje s teplotou vzduchu, relatívnou vlhkosťou, rýchlosťou a smerom vetra, výškou snehu, radiáciou a rosným bodom.

Pre oblasť Západných Tatier bol v sezónach, ktoré sú k dispozícii, určovaný jeden lavínový stupeň pre celý deň a všetky nadmorské výšky. Pre oblasť Wattener Lizum bolo pre jeden deň určovaných viac lavínových stupňov. Rôzna predpoveď sa robila pre ráno a pre poobedie a vychádzala aj z predpovede počasia na daný deň. V niektorých prípadoch bol ešte určovaný stupeň pre rôzne nadmorské výšky.

### 4. Riešenie vypadnutých údajov

Vážnym problémom, ktorý sa vyskytuje pri akýchkoľvek snímačoch je výpadok údajov. Tieto výpadky údajov môžu vzniknúť chybou komunikácie, či poškodením snímača. Ak je výpadok len v jednej z AMS, tak na základe vzájomnej polohy staníc sa väčšina údajov dá dopočítať. No častejšie sa vyskytuje výpadok vo všetkých AMS naraz. Z toho dôvodu je dôležité dosimulovať vypadnuté údaje, aby výsledky ohľadne lavínového nebezpečenstva boli, čo najpresnejšie. Na tento účel bol pre každý meteorologický údaj navrhnutý, realizovaný a overený spôsob výpočtu ako tieto výpadky dopočítať. Výpadky údajov v tejto práci rozdeľujeme podľa dĺžky výpadku do troch skupín:

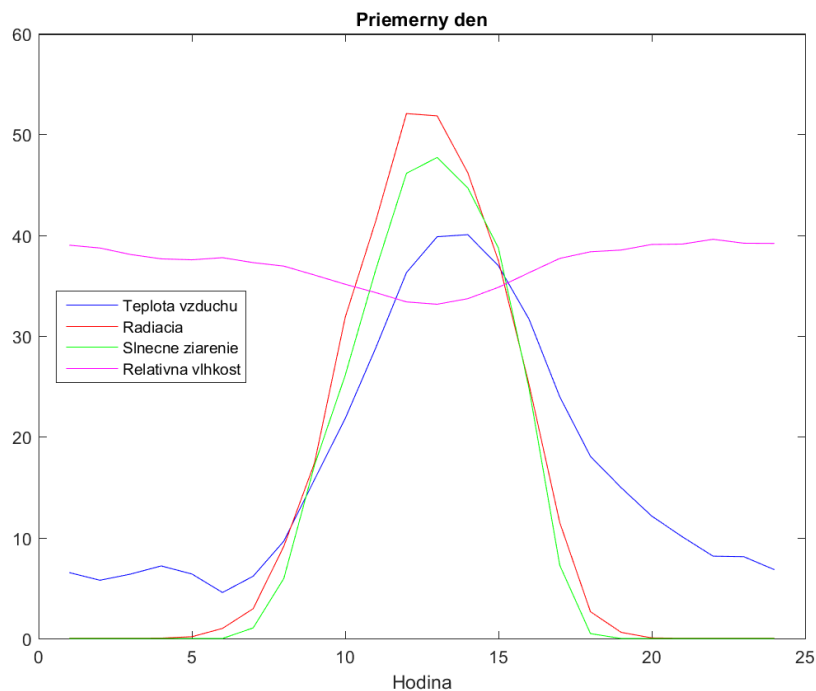


- Výpadok údajov maximálne 1 hodinu.
- Výpadok údajov maximálne 6 hodín.
- Výpadok údajov dlhší ako 6 hodín.

Pre teplotu vzduchu, relatívnu vlhkosť, radiáciu a slnečné žiarenie bol vypočítaný priemerný deň. Priemerný deň predstavuje priebeh na základe údajov z celej zimy. Vypočíta sa ako suma hodnôt za celú zimu v danej hodine vydelená počtom dní (údajov) a toto sa zopakuje pre každú hodinu. Priemerný deň je vyjadrený nasledujúcim vzťahom:

$$PD_i = \frac{\sum_1^b x_i}{b} \quad (4.1)$$

Kde  $i$  je hodina z intervalu  $\langle 0;23 \rangle$ ,  $b$  je počet dní, z ktorých sa určuje priemerný deň a  $x$  je určovaná hodnota priemerného dňa (napr. teplota). Výsledný priebeh priemerného dňa pre teplotu vzduchu, radiáciu, slnečné žiarenie a relatívnu vlhkosť pre sezónu 2011/2012 je na obrázku 4.1.



**Obrázok 4.1** Zobrazenie priebehu priemerného dňa pre teplotu vzduchu [°C] (10x vynásobená a zväčšená o 40°C), radiácia (zmenšená 10x)[W/m²], slnečné žiarenie [min] a relatívna vlhkosť [%] (zmenšená 2x).

Z obrázku pre priemerný deň všetkých veličín je vidieť, že priemerné dni pre teplotu vzduchu, radiáciu a slnečné žiarenie majú podobný priebeh, pretože tieto veličiny sú vzájomne závislé. Pri náraste slnečného žiarenia začína narastať aj teplota vzduchu. Relatívna vlhkosť je tiež závislá od ostatných premenných a naopak, ako teplota a relatívna vlhkosť klesá s narastajúcim slnečným žiarením a teda aj so zvyšujúcou sa teplotou.

#### 4.1. Výpadok údajov do 1 hodiny (1 údaj)

V prípade, že v údajoch s hodinovou frekvenciou je chýbajúci len jeden údaj, tak sa tento údaj nahradí dvomi rôznymi spôsobmi a to podľa vzťahu:

$$x_n = \begin{cases} \exists x_{n+1}, & \frac{(x_{n-1}+x_{n+1})}{2} \\ \nexists x_{n+1}, & x_{n-1} \end{cases} \quad (4.2)$$

#### 4.2. Výpadok údajov nad 1 hodinu

Výpadky v trvaní niekoľkých hodín už čiastočne ovplyvňujú presnosť určenia lavínového stupňa. Z toho dôvodu je dôležité vedieť tieto údaje dopočítať, aby presnosť určenia lavínového stupňa bola vyššia. Aj v prípade niekoľkohodinového výpadku záleží pri výpočte na tom, či existujú namerané údaje po výpadku alebo výpadkom končia údaje, teda výpadok stále trvá aj v čase určovania lavínového nebezpečenstva.

##### Teplota vzduchu

Teplota vzduchu je veličina, ktorej funkcia má v čase sínusový tvar. Na základe tejto vlastnosti sa dopočítajú hodnoty teploty vzduchu na základe trendu z predchádzajúcich hodnôt. Z údajov za celú zimnú sezónu, ktoré sú k dispozícii sa vypočíta priemerný priebeh dňa. Pri výpadku sa pripočítava rozdiel na základe tohto priemerného dňa s tým, že sa sleduje aj posledných 24 hodín.

Na určenie lavínového nebezpečenstva sa využíva aj teplota v čase, kedy sa lavínové nebezpečenstvo určuje. V tomto prípade sa dopočíta táto hodnota ako pri teplote vzduchu, rozdiel je následne v spracovaní týchto údajov pre neurónovú sieť, kde tejto hodnote je priradená menšia váha. Teplota vzduchu sa dopočíta pomocou nasledujúcich vzťahov

$$fX_i = X_k + (k - i)P_z + (PD(T_i) - PD(T_k)), i \in \langle k + 1, k + n \rangle \quad (4.3)$$

Kde  $k$  predstavuje index posledného platného merania pred výpadkom,  $n$  je dĺžka výpadku,  $P_z$  je priemerná zmena hodnoty v posledných  $n$  platných údajov vypočítaná ako:

$$P_z = \frac{1}{n} \sum_{t=k-n+1}^k (X_{t+1} - X_t) \quad (4.4)$$

A PD je funkcia, ktorá vráti hodnotu priemerného dňa pre danú veličinu v čase  $T_i$ , kde  $T_i$  predstavuje čas (v hodinách) pre index  $i$ .

Analogicky k doprednému odhadu (trend z údajov pred výpadkom) bol vytvorený odhad na základe platných údajov, ktoré boli získané po výpadku, ako :

$$bX_i = X_k + (i - k)P_z + (PD(T_k) - PD(T_i)), i \in \langle k - 4, k - n \rangle \quad (4.5)$$

Na základe takto získaných odhadov vypadnutých dát bol navrhnutý priemerný odhad vypadnutej veličiny ako:

$$X_i = \frac{fX_i + bX_i}{2}, i \in \langle k + 1, k + n \rangle \quad (4.6)$$

V prípade, kedy nie sú k dispozícii údaje po výpadku, tak sa počíta len dopredný odhad. Ďalšie veličiny, pre ktoré bol počítaný priemerný deň sa vypočítajú obdobným spôsobom.

## 5. Spracovanie pre neurónovú sieť

Dôležitým krokom pri automatizovanom predikovaní stupňa lavínového nebezpečenstva je výber parametrov, na základe ktorých sa bude určovať stupeň lavínového nebezpečenstva. Pre tento systém je dôležité predspracovanie týchto parametrov, ktoré budú vstupovať do neurónovej siete. V predspracovaní sa berie ohľad na to, aký vplyv majú jednotlivé parametre na lavínové nebezpečenstvo. Podľa toho sú v tejto kapitole navrhnuté funkcie pre jednotlivé parametre.

V tejto práci bolo celkovo použitých 15 parametrov a to: teplota vzduchu v čase určovania stupňa, priemer teploty vzduchu za posledných 24 hodín, zmena teploty vzduchu za 24 hodín (rozdiel teploty pred 24 hodinami a aktuálnej), rozdiel maximálnej a minimálnej teploty vzduchu za 24 hodín, výška snehu v čase určovania, nový sneh za 24/72/120 hodín, slnečné žiarenie za 24 hodín a priemerné slnečné žiarenie za hodinu, maximálna radiácia za 24 hodín, priemerná radiácia za hodinu, zrážky, priemerná relatívna vlhkosť za 24 hodín, maximálny vietor a smer v zonálnej a meridiálnej zložke, teplota v snehu v jednotlivých snímačoch.

### 5.1. Teplota vzduchu

Pri teplote vzduchu sa sleduje aktuálna a priemerná teplota a denný trend teploty a rozdiel maximálnej a minimálnej teploty za 24 hodín.

#### Aktuálna a priemerná teplota vzduchu

Sneh má najstabilnejšie podmienky pri teplote okolo  $-4^{\circ}\text{C}$  a naopak k nestabilitám dochádza pri vyšších teplotách ako  $5^{\circ}\text{C}$  a nižších ako  $-10^{\circ}\text{C}$ . V tejto práci sa za čas posledného merania pred určením lavínového stupňa považuje 8. hodina. Preto je predpoklad, že teplota bude mierne stúpať počas dňa. Intervaly, ktorým je priradená rôzna funkcia, sú definované podľa vplyvu teploty vzduchu na stabilitu snehu. Tieto funkcie sú lineárne.

$$y = \begin{cases} 1, & x < -10 \\ 0,2x - 1, & x \in < -10, -5 > \\ 0,001, & x \in < -5, -3 > \\ 0,125x + 0,375, & x \in (-3,5 > \\ 1, & x < 5 \end{cases} \quad (5.1)$$

Kde  $x$  je teplota vzduchu v °C a  $y$  je hodnota v rozsahu od 0 do 1 pre teplotu vzduchu.

### Denný trend teploty vzduchu

V prípade denného trendu sa neočakávajú veľké zmeny teploty. Preto je funkcia na normovanie denného trendu lineárna s obojstranným ohraničením.

$$y = \begin{cases} \frac{|x|}{5}, & |x| < 5 \\ 1, & |x| \geq 5 \end{cases} \quad (5.2)$$

Kde  $x$  je rozdiel teploty vzduchu v °C nameranej v čase určovania stupňa lavínového nebezpečenstva a 24 hodín predtým a  $y$  je hodnota v rozsahu od 0 do 1 pre denný trend.

### Rozdiel maximálnej a minimálnej teploty vzduchu za 24 hodín

V prípade priebehu teploty vzduchu počas 24 hodín sa predpokladá, že v ideálnych podmienkach nedochádza k výrazným zmenám počas dňa. Ideálne podmienky pre stabilitu snehu sú minimálne rozdiely teploty. Počas väčšiny zimných dní sa zmena teploty počas dňa nachádza v rozmedzí od približne 5°C do približne 8°C.

$$y = \begin{cases} 0,001, & x \leq 3 \\ \frac{x-3}{7}, & x \in (3, 10 > \\ 1, & x > 10 \end{cases} \quad (5.3)$$

Kde  $x$  je rozdiel maximálnej a minimálnej teploty vzduchu v °C počas 24 hodín a  $y$  je hodnota v rozsahu od 0 do 1 pre denný trend.

## 5.2. Výška snehu

Informácie o výške snehu sú dôležitou súčasťou pri predpovedi lavínového nebezpečenstva. Pracuje sa s dvomi údajmi, ktoré vyplývajú z výšky snehu a to: celková výška snehu v čase určovania stupňa lavínového nebezpečenstva a množstvo nového snehu za posledných 72 hodín.

### Celková výška snehu

Keďže v Západných Tatrách ako aj vo Wattener Lizum je rôzny povrch (trávnatý, skalnatý,...), preto aktuálne nie je možné prispôbiť spracovanie celkovej výšky snehu do intervalu od 0 do 1 na základe povrchu pod snehom. Aj z toho dôvodu je funkcia celkovej výšky snehu lineárna s horným ohraničením.

$$y = \begin{cases} \frac{x}{150}, & x \leq 150 \\ 1, & x > 150 \end{cases} \quad (5.4)$$

Kde  $x$  je celková výška snehu v centimetroch a  $y$  je hodnota v rozsahu od 0 do 1 pre celkovú výšku snehu.

### Nový sneh

Funkcia pre nový sneh bola vytvorená na základe vlastností príbytku/úbytku snehu. Pri výraznom úbytku snehu buď nastalo výrazné oteplenie alebo padla lavína v mieste merania a preto sa predpokladá zvýšené riziko padnutia lavíny. Naopak pri minimálne sa meniacej snehovej pokrývke je predpoklad, že teplota ako aj ďalšie podmienky sú stabilné.

$$y = \begin{cases} 1, & x < -25 \\ \frac{|x| \log|x|}{25 \log 25}, & x \in \langle -25, -1 \rangle \\ 0,001, & x \in (-1, 1) \\ \frac{x^2 \log|x|}{40^2 \log 40}, & x \in \langle 1, 40 \rangle \\ 1, & x > 40 \end{cases} \quad (5.5)$$

Kde  $x$  je výška nového snehu v centimetroch a  $y$  je hodnota v rozsahu od 0 do 1 pre výšku nového snehu.

### 5.3. Slnčné žiarenie a radiácia

Slnčné žiarenie a radiácia vzájomne spolu súvisia, pričom slnečné žiarenie popisuje koľko minút svietilo slnko a radiácia popisuje intenzitu s akou dopadali slnečné lúče. Obidva parametre sú spracované lineárnou funkciou.

#### Slnčné žiarenie

Slnčné žiarenie je prepočítané podľa toho, či je to hodinový údaj alebo údaj za 24 hodín. Funkcia je teda závislá od toho, akú dobu reprezentuje vstupná hodnota.

$$y = \frac{x}{t} \quad (5.6)$$

Kde  $x$  je slnečné žiarenie v minútach a  $y$  je hodnota v rozsahu od 0 do 1 pre slnečné žiarenie.  $t$  je sledovaný čas.

#### Radiácia

Pri radiácii sa sledujú dve parametre a to maximálna hodnota radiácie za 24 hodín a priemerná hodnota radiácie za 24 hodín. Obidva parametre majú lineárnu funkciu s ohraničením. Funkcia pre maximálnu radiáciu za 24 hodín je v tvare:

$$y = \begin{cases} 0,001, & x = 0 \\ \frac{x}{750}, & x \in (0, 750) \\ 1, & x > 750 \end{cases} \quad (5.7)$$

Kde  $x$  je maximálna radiácia vo  $W/m^2$  a  $y$  je hodnota v rozsahu od 0 do 1 pre maximálnu radiáciu za 24 hodín.

Funkcia pre priemernú hodnotu radiácie za 24 hodín je v tvare:

$$y = \begin{cases} 0,001, & x = 0 \\ \frac{x}{250}, & x \in (0, 250) \\ 1, & x > 250 \end{cases} \quad (5.8)$$

Kde  $x$  je priemerná radiácia vo  $W/m^2$  a  $y$  je hodnota v rozsahu od 0 do 1 pre priemernú radiáciu za 24 hodín.

#### 5.4. Zrážky a relatívna vlhkosť

Relatívna vlhkosť je závislá ako od zrážok, tak aj od teploty. V prípade zrážok sa používajú len dva stavy a to, buď zrážky sú alebo sú nulové, teda buď majú hodnotu 1 alebo 0. Funkcia relatívnej vlhkosti je lineárna, keďže je meraná v percentách, tak je predelená hodnotou 100%.

$$y = \frac{x}{100} \quad (5.9)$$

Kde  $x$  je relatívna vlhkosť v percentách a  $y$  je hodnota v rozsahu od 0 do 1 pre relatívnu vlhkosť za 24 hodín.

#### 5.5. Rýchlosť a smer vetra

Rýchlosť a smer vetra je dôležitá informácia, ktorá popisuje v akom smere môže byť sneh naviaty na svahoch, prípadne v akom smere môže dochádzať k presunom snehových vločiek. Sledujú sa dve informácie o vetre a to maximálna rýchlosť a smer vetra za 24 hodín a priemerná rýchlosť a smer vetra za 24 hodín. Funkcia pre rýchlosť vetra je navrhnutá pomocou Gaussovej chybovej funkcie a pre maximálnu rýchlosť má tvar:

$$y = 0,5 \operatorname{erf}(0,471405(x - 3)) + 0,5 \quad (5.10)$$

Kde  $x$  je maximálna rýchlosť vetra v m/s,  $\operatorname{erf}$  je Gaussova chybová funkcia a  $y$  je hodnota v rozsahu od 0 do 1 pre maximálnu rýchlosť vetra. A pre priemernú rýchlosť má tvar:

$$y = 0,5 \operatorname{erf}(0,6285(x - 2,25)) + 0,5 \quad (5.11)$$

Kde  $x$  je priemerná rýchlosť vetra v m/s,  $\operatorname{erf}$  je Gaussova chybová funkcia a  $y$  je hodnota v rozsahu od 0 do 1 pre priemernú rýchlosť vetra. Smer vetra je udávaný v uhlových stupňoch a teda hodnota smeru je vydelená  $360^\circ$ .

$$y = \frac{x}{360} \quad (5.12)$$

Kde  $x$  je smer vetra v stupňoch a  $y$  je smer vetra z rozsahu 0 až 1.

## 5.6. Teplota v snehu

Teplota je meraná pomocou snímačov, ktoré sú rozmiestnené každých 20 centimetrov do výšky 2 metrov. Pre stabilnú vrstvu je predpoklad, že sa teplota v čase takmer nemení a teda jej derivácia je blízka nule. Preto pre teplotu v snehu sú počítané derivácie v čase pre jednotlivé namerané hodnoty do výšky podľa celkovej výšky snehu. V prípade, ak je derivácia väčšia ako 1, tak je hodnota pre teplotu snehu ( $y$ ) nastavená na 1, inak je nastavená na 0.

## 6. Neurónová sieť

V tejto práci je ako učiaci mechanizmus zvolená neurónová sieť. Vstupné údaje pre neurónovú sieť sú meteorologické údaje a údaje o snehu popísané v predchádzajúcich kapitolách a výstupom je stupeň lavínového nebezpečenstva pre daný deň. V meraných údajoch dochádza niekedy k dlhodobému výpadku niektorých snímačov a zároveň pre oblasť Wattener Lizum a Západné Tatry sú merané rôzne údaje. Z toho dôvodu je vytvorených niekoľko rôznych sád vstupných údajov, ktoré sa líšia počtom parametrov ako aj ich kombináciou. Jednotlivé kombinácie je možné vidieť v tabuľke 6.1, kde jednotlivé sady obsahujú tie parametre, ktorých stĺpec je označený krížikom.

Tabuľka 6.1 Vstupné sady a parametre, ktoré obsahujú pre neurónové siete.

Sada / parameter	č.1	č.2	č.3	č.4
Teplota vzduchu o 8 hod	x	x	x	x
Priemerná teplota vzduchu	x	x	x	x
Teplota vzduchu rozdiel za 24 hodín	x	x	x	x
Teplota vzduchu max - min	x	x	x	x
Aktuálna výška snehu	x	x	x	x
Výška nového snehu za 72 hodín	x	x	x	x
Slnečné žiarenie za 24 hodín	x	x	-	-
Priemerná hodnota slnečného žiarenia	x	-	-	-

Sady č. 1, 2 a 3 obsahujú parametre, ktoré sú dostupné len pre Západné Tatry. Sada č. 4 je sada, ktorá obsahuje také parametre, ktoré sú dostupné aj pre Západné Tatry a aj pre Wattener Lizum. Sada č.2 je pre situáciu, kedy nie sú dostupné informácie o vetre a zrážkach, keďže tieto údaje nie sú dopyčované pri výpadkoch.

### 6.1. Nastavenie neurónových sietí

Pri použití neurónových sietí existuje množstvo variácií, ktoré sa dajú použiť. V tejto práci sú použité neurónové siete v softvéri Matlab. Je to dopredná neurónová sieť, ktorá má na skrytých vrstvách neuróny so sigmoidálnym tvarom. Na výstupnej vrstve sú neuróny v lineárnom tvare. Táto práca sa zameriava na rôzne nastavenia neurónových sietí a ich porovnanie. V prvej časti sú spustené učenia

neurónových sietí pre všetky navrhnuté sady parametrov pri rovnakom nastavení a tieto výsledky sú porovnané. Táto neurónová sieť má 3 skryté vrstvy s 8, 4 a 2 neurónmi, použitý Levenberg-Marquardt algoritmus učiacej funkcie. Následne sa z týchto 4 matíc použijú len niektoré na zhodnotenie ďalších nastavení neurónových sietí.

Všetky údaje sú rozdelené do troch skupín a to na tréningovú sadu údajov, validačnú sadu údajov a na testovaciu sadu údajov, v ktorých sú rovnomerne rozdelené dni podľa stupňov lavínového nebezpečenstva. V tabuľke 6.2 sú počty dní s daným lavínovým stupňom pre danú sadu a oblasť. Tréningová sada sa používa na tréning neurónovej siete, validačnú sadu používa neurónová sieť, aby určila, kedy je neurónová sieť naučená, aby nebola preučená. A testovacia sada slúži na nezávislé overenie naučenia neurónovej siete.

**Tabuľka 6.2 rozdelenie údajov do jednotlivých sád pre neurónovú sieť v Západných Tatrách a vo Wattener Lizum**

Oblasť/ stupeň	Západné Tatry			Wattener Lizum		
	Tréning	Validácia	Test	Tréning	Validácia	Test
1	99	21	20	24	1	1
2	291	63	63	258	58	58
3	129	29	29	310	69	69
4	19	2	3	16	3	3
5	0	0	0	0	0	0

V nameraných údajoch v Západných Tatrách, ktoré vstupovali do predspracovania pre neurónové siete, bolo doplnených 30 výpadkov v trvaní 1 hodinu, 1 výpadok v trvaní 2 hodiny, 1 výpadok v trvaní 3 hodiny, 1 výpadok v trvaní 7 hodín a 1 výpadok v trvaní 24 hodín.

## 7. Zhodnotenie výsledkov - neurónové siete

Výstup z neurónovej siete je stupeň lavínového nebezpečenstva pre daný deň, pričom tento stupeň nie je určený ako celé číslo od 1 do 5 ako to určujú experti, ale je určený na desatinné číslo.

Pri určovaní stupňa lavínového nebezpečenstva sa často stáva, že aj experti sa rozhodujú medzi dvomi stupňami. V takýchto prípadoch sa stáva, že dvaja experti by pri rovnakých údajoch určili rôzny stupeň. Navrhovaný systém poskytuje výsledok v desatinných číslach a aj vďaka tomu môže expertov smerovať k určeniu rovnakého stupňa v nerozhodných situáciách. Preto v druhej časti zhodnotenia sa bude venovať určeniu v desatinných číslach. Porovnávaná bude priemerná hodnota rozdielov medzi určeným stupňom expertmi a neurónovou sieťou, priemerná hodnota rozdielov v absolútnych hodnotách, percentuálny podiel kedy tento rozdiel presiahol hodnotu 1, hodnotu 0,75 a hodnotu 0,5.



Všetky učenia neurónových sietí boli spustené minimálne desaťtisíckrát, aby bolo zabezpečené, že pri každom nastavení bolo možné vybrať tú najlepšiu neurónovú sieť zo všetkých. Je to z toho dôvodu, že učenie vychádza z náhodných hodnôt, ktoré sú priradené vstupným hodnotám.

### 7.1. Porovnanie navrhnutých sád

V tomto porovnaní boli použité 4 vstupné sady na tréovanie neurónovej siete z tabuľky 6.1. Neurónová sieť bola pre všetky sady nastavená s rovnakými parametrami. Neurónová sieť mala 3 skryté vrstvy po 8, 4 a 2 neuróny, bol použitý Levenberg-Marquardt algoritmus učiacej funkcie fitnet.

Zhodnotenie vypočítaného stupňa lavínového nebezpečenstva je v tabuľke 7.1. Tabuľka obsahuje priemery a percentuálne hodnoty pre rozdiely medzi vypočítaným a určeným stupňom lavínového nebezpečenstva. Prvý stĺpec obsahuje priemernú hodnotu rozdielov v absolútnych hodnotách, druhý stĺpec v reálnych hodnotách, tretí stĺpec štandardnú odchýlku, štvrtý stĺpec percento dní, ktorých stupeň bol určený s väčším rozdielom ako 0,5 stupňa, piaty stĺpec s rozdielom väčším ako 0,75 stupňa a posledný stĺpec s rozdielom väčším ako 1 stupeň. V tabuľke sú tučným podčiarknutým písmom hodnoty, ktoré sú v danom stĺpci najnižšie a kurzívou sú hodnoty, ktoré sú pre daný stĺpec najvyššie.

Tabuľka 7.1 porovnanie určenia stupňa lavínového nebezpečenstva pre jednotlivé sady

Vstupná sada	Priemer v absolútnych	Priemer	Štandardná odchýlka	Percento nad 0,5	Percento nad 0,75	Percento nad 1
1	0,45	-0,03	<u>0,55</u>	37,76	15,36	6,38
2	0,44	-0,02	<u>0,55</u>	36,20	<b>14,06</b>	<b>6,25</b>
3	0,44	<b>-0,00</b>	0,58	36,07	22,92	9,77
4	<b>0,43</b>	<b>-0,00</b>	0,56	<b>35,03</b>	20,96	7,68

Priemerný rozdiel pre všetky sady sa pohybuje medzi 0,43 až 0,45 stupňa rovnomerne do oboch smerov. Z posledných troch stĺpcov je už vidieť rozdiely medzi sadami. Keďže stupne určované expertmi sú na celé čísla, tak takmer vždy dochádza k rozdielom medzi určeným a vypočítaným stupňom. Pri percentuálnom podiele rozdielov nad 0,5 stupňa nie sú viditeľné výrazné rozdiely medzi sadami. Rozdiel je výrazný hlavne pri percentuálnom podiele rozdielov nad 0,75 stupňa. Veľké rozdiely dosahovala sada č.3, kde pre rozdiely nad 1 stupeň a 0,75 stupňa dosahuje najvyššie hodnoty, aj keď nad 0,5 stupňa dosahuje lepšie výsledky ako sady č.1 a 2, pričom tieto sady majú najnižšiu štandardnú odchýlku. Sada č.2 dosahuje lepšie výsledky ako sada č.1, ktorá obsahuje aj informácie o zrážkach a vetre, pričom ale výsledky sú veľmi porovnateľné. Najväčší rozdiel medzi nimi je v percente dní, ktorých rozdiel bol väčší ako 0,5 stupňa.

## 7.2. Zhodnotenie podľa vrstiev

V tejto časti budú učené ďalšie 4 neurónové siete, ktoré sa budú odlišovať v počte skrytých vrstiev ako aj v počte neurónov na týchto vrstvách. Okrem pôvodného nastavenia vrstiev z predchádzajúcej časti budú použité 4 vrstvy po 12 neurónov, tri vrstvy s 10, 8 a 6 neurónmi, dve vrstvy s 10 a 5 neurónmi a s 15 a 9 neurónmi a jedna vrstva s 10 neurónmi. Zhodnotenie vypočítaného stupňa lavínového nebezpečenstva pre rôzne nastavenia skrytých vrstiev je v tabuľke 7.2.


Tabuľka 7.2 porovnanie určenia stupňa lavínového nebezpečenstva pre rôzne nastavené skryté vrstvy

Počet neurónov na vrstvách	Priemer v absolútnych	Priemer	Štandardná odchýlka	Percento nad 0,5	Percento nad 0,75	Percento nad 1
8, 4, 2	0,45	-0,03	0,55	37,76	15,36	6,38
12, 12, 12,12	<b>0,38</b>	-0,05	<b>0,50</b>	28,13	13,80	<b>5,47</b>
10, 8, 6	0,40	0,02	0,51	31,25	14,45	<b>5,47</b>
10, 5	0,44	<b>-0,00</b>	0,57	36,98	20,05	8,07
15, 9	0,44	<b>-0,00</b>	0,57	39,06	20,44	7,42
10	<b>0,38</b>	-0,02	<b>0,50</b>	<b>26,30</b>	<b>12,50</b>	5,73

Priemerná odchýlka všetkých naučených neurónových sietí je v okolí nuly a v absolútnych číslach je v rozsahu od 0,38 do 0,45. Najlepšie výsledky dosahujú nastavenia so štyrmi vrstvami s 12 neurónmi a s jednou vrstvou s 10 neurónmi, kde výsledky sú veľmi porovnateľné.

## 7.3. Zhodnotenie podľa učiacej funkcie

Pri použití fitnet neurónovej siete bolo použitých dokopy 12 rôznych učiacich funkcií, z ktorých sú všetky výsledky pre sadu č. 1 a jednu skrytú vrstvu s 10 neurónmi a tri skryté vrstvy s 10, 8 a 6 neurónmi. Z učiacich funkcií najlepšie výsledky dosahovala Bayesovská regularizácia a uspokojivé výsledky dosahoval už v predchádzajúcich častiach použitý Levenberg-Marquardt algoritmus. Všetky ostatné učiace funkcie dosahovali neuspokojivé výsledky. Na obrázku 7.1 je histogram rozloženia chyby pre sadu č.1 s tromi skrytými vrstvami s 10, 8 a 6 neurónmi a s použitím bayesovskej regularizácie.



**Obrázok 7.1** Histogram chyby určenia stupňa lavínového nebezpečenstva pre sadu č.1 a použitú Bayesovskú regularizáciu.

V nasledujúcej tabuľke 7.3 je porovnanie rôznych vrstiev pre sadu č. 1 s použitím Bayesovskej regulácie ako algoritmu učiacej funkcie.

**Tabuľka 7.3** porovnanie určenia stupňa lavínového nebezpečenstva pre rôzne nastavené skryté vrstvy pri použití Bayesovskej regularizácie ako učiacej funkcie.

Počet neurónov na vrstvách	Priemer v absolútnych	Priemer	Štandardná odchýlka	Percento nad 0,5	Percento nad 0,75	Percento nad 1
12,12,12,12	0,54	<u>0,00</u>	0,73	45,70	45,70	21,35
10,8,6	<u>0,28</u>	<u>0,00</u>	<u>0,40</u>	<u>17,32</u>	<u>5,99</u>	3,13
10,5	0,33	0,01	0,44	21,09	8,07	2,99
10	0,37	0,02	0,47	26,69	10,03	4,04

Pri použití Bayesovskej regularizácie ako učiacej funkcie dosahuje najlepšie výsledky nastavenie s tromi skrytými vrstvami s 10, 8 a 6 neurónmi. Kde je len približne 17% dní, kedy bol rozdiel medzi určeným a vypočítaným stupňom lavínového nebezpečenstva viac ako 0,5 stupňa.

#### 7.4. Zhodnotenie údajov z Wattener Lizum

Posledné zhodnotenie je zhodnotenie výsledkov pre maticu č.4, ktorá obsahuje údaje aj pre Západné Tatry aj pre Wattener Lizum. V nasledujúcich tabuľkách sú kontingenčné matice, kde riadky sú algoritmom vypočítané stupne a stĺpce sú expertom určené.

**Tabuľka 7.4 kontingenčná tabuľka pre 4 skryté vrstvy s 12 neurónmi, pri použití metódy č.4 a algoritmu Bayesovskej regularizácie a vpravo pre 3 skryté vrstvy s 10, 8 a 6 neurónmi.**

<b>expert / algoritmus</b>	<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>	<b>suma</b>		<b>expert / algoritmus</b>	<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>	<b>suma</b>
<b>1</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>		<b>1</b>	<b>25</b>	<b>5</b>	<b>4</b>	<b>0</b>	<b>0</b>	<b>33</b>
<b>2</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>		<b>2</b>	<b>2</b>	<b>332</b>	<b>37</b>	<b>1</b>	<b>0</b>	<b>372</b>
<b>3</b>	<b>26</b>	<b>374</b>	<b>448</b>	<b>22</b>	<b>0</b>	<b>870</b>		<b>3</b>	<b>0</b>	<b>37</b>	<b>397</b>	<b>8</b>	<b>0</b>	<b>443</b>
<b>4</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>		<b>4</b>	<b>0</b>	<b>0</b>	<b>8</b>	<b>13</b>	<b>0</b>	<b>21</b>
<b>5</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>		<b>5</b>	<b>0</b>	<b>0</b>	<b>1</b>	<b>0</b>	<b>0</b>	<b>1</b>
<b>suma</b>	<b>26</b>	<b>374</b>	<b>448</b>	<b>22</b>	<b>0</b>	<b>870</b>		<b>suma</b>	<b>26</b>	<b>374</b>	<b>448</b>	<b>22</b>	<b>0</b>	<b>870</b>

Problém, ktorý je viditeľný výrazne pri učení na údajoch z Wattener Lizum, ale takisto sa vyskytuje aj v údajoch zo Západných Tatier, je nerovnomerné rozloženie tréningových údajov medzi všetky stupne lavínového nebezpečenstva. Pri údajoch z Wattener Lizum z 870 dní len 26 dní bolo so stupňom 1 a len 22 dní zo stupňom 4. Preto je možné vidieť v kontingenčných tabuľkách vyššie, že okrem nastavenia s najlepšimi výsledkami (tri vrstvy s 10, 8 a 6 neurónmi a použitím Bayesovskej regularizácie), žiadne nastavenie nedostáva výstupy stupňa iné ako stupeň 2 a 3. V údajoch zo Žiarskej chaty to bolo menej viditeľné, keďže tam bol stupeň 1 zastúpený vo väčšom pomere, tam to bolo vidieť najmä na stupni 4. Ideálne pre učenie by bolo rozloženie, ktoré je v rovnomernom pomere medzi všetkými stupňami.

Najlepšie a zároveň najhoršie výsledky boli dosiahnuté pri použití Bayesovskej regularizácie. Pri použití 4 vrstiev, bolo približne len 50% dní určených presne, naopak pri nastavení troch skrytých vrstiev bolo takmer 90% dní určených presne. Pri použití Levenberg-Marquardt algoritmu sú výsledky porovnateľné pre všetky nastavenia a dosahujú približne 70-75% presne určených dní.

V druhej časti zhodnotenia sú porovnania niektorých použitých metód reprezentácie stupňov lavínového nebezpečenstva. V popise nastavenia prvé číslo definuje, ktorá metóda reprezentácie stupňa lavínového nebezpečenstva bola použitá, druhé číslo popisuje, koľko skrytých vrstiev bolo použitých 1 (10 neurónov), 2 (10 a 5 neurónov), 3 (10, 8 a 6 neurónov) a 4 (12 neurónov). Posledné dve písmená definujú použitú učiacu funkciu br – Bayesovská regularizácia a lm - Levenberg-Marquardt algoritmus.

Tabuľka 7.5 porovnanie určenia stupňa lavínového nebezpečenstva pre Wattener Lizum.

Nastavenie	Priemer v absolútnych	Priemer	Štandardná odchýlka	Percento nad 0,5	Percento nad 0,75	Percento nad 1
4_1br	0,37	<b>0,00</b>	0,46	27,24	10,46	2,87
4_2br	0,36	<b>0,00</b>	0,45	27,13	9,08	<b>2,07</b>
4_3br	<b>0,26</b>	<b>0,00</b>	<b>0,37</b>	<b>11,84</b>	<b>5,52</b>	2,53
4_4br	0,55	0,01	0,60	48,51	<b>5,52</b>	5,52
4_1lm	<b>0,41</b>	<b>-0,01</b>	<b>0,50</b>	34,71	13,22	4,02
4_2lm	0,43	-0,03	0,52	36,09	<b>11,95</b>	4,83
4_3lm	<b>0,41</b>	0,03	<b>0,50</b>	33,10	12,87	<b>3,79</b>
4_4lm	<b>0,41</b>	<b>-0,01</b>	<b>0,50</b>	<b>31,49</b>	12,07	4,71

Celkovo najlepšie výsledky dosiahlo nastavenie pri použití jednotného stupňa lavínového nebezpečenstva (metóda 4) použitím Bayesovskej regularizácie s tromi skrytými vrstvami s 10, 8 a 6 neurónmi. Len približne 5% dní bolo určených s rozdielom medzi vypočítaným a určeným stupňom nad 0,75 stupňa, čo bolo aj v prípade pri štyroch vrstvách, no na rozdiel od 4 vrstiev len necelých 12% dní bolo určených s rozdielom nad 0,5 stupňa, čo pri 4 vrstvách bolo až 48% dní, čo je celkovo najhorší výsledok.

Pri použití štvrtej reprezentácie stupňov a Levenberg-Marquardt algoritmu dosahujú všetky vrstvy porovnateľné výsledky. Štandardná odchýlka je v okolo 0,5 stupňa a aj percento dní, kedy boli rozdiely nad 0,5, 0,75 a 1 stupeň boli porovnateľné.

# ZÁVER

Táto práca obsahuje základné teoretické spracovanie o vlastnostiach lavín, ako vznikajú a čím sú ovplyvňované. Okrem toho práca obsahuje aj prehľad prác, ktoré sa venujú problematike lavín v oblasti predikcie nebezpečenstva vzniku lavín. Záverečná časť sa už venuje praktickému návrhu a reálnemu spracovaniu predikcie lavínového nebezpečenstva.

## Zhodnotenie dosiahnutých výsledkov

Prvá časť praktickej realizácie sa venuje spracovaniu vypadnutých údajov. Tieto údaje boli dopĺňané buď pomocou priemeru hodnôt pred a po výpadku, keď sa jednalo o výpadok jedného údaju, čo nemalo výrazný vplyv na spracovanie. Výpadok v trvaní niekoľko hodín už dokáže ovplyvniť predikciu lavínového nebezpečenstva. Pre doplnenie týchto údajov je navrhnuté spracovanie priemerného dňa pre meranú veličinu a zimnú sezónu. Doplnené údaje pomocou priemerného dňa mali 80% úspešnosť, ktorú je možné považovať za veľmi dobrú.

V druhej časti je navrhnutý výber parametrov na vstup do neurónových sietí a spracovanie týchto parametrov pomocou funkcií, ktoré odzrkadľujú vlastnosti lavín. Takto spracované údaje sú súčasťou poslednej časti tejto práce, kde sú použité neurónové siete. Pomocou neurónových sietí je predikovaný stupeň lavínového nebezpečenstva pre daný deň.

Posledná časť by sa dala rozdeliť na dve časti a to časť, v ktorej sa pracuje s údajmi zo Západných Tatier a časť, v ktorej sa pracuje s údajmi z Wattener Lizum. V oboch prípadoch boli dosiahnuté veľmi dobré výsledky.

V Západných Tatrách mala veľmi dobré výsledky sada parametrov, ktorá obsahovala všetky parametre, u ktorých sa predpokladalo, že môžu ovplyvniť lavínové nebezpečenstvo. Nastavenia rôznych skrytých vrstiev s rôznym počtom neurónov nevykazovali medzi sebou výrazné rozdiely. Veľké rozdiely boli pri použití rôznych učiacich funkcií, ale taký bol predpoklad už pred ich použitím na základe ich vlastností. Najlepšie výsledky dosahovala Bayesovská regularizácia, kde sa úspešnosť presného určenia stupňa lavínového nebezpečenstva blížila k 80%. Prípady, kedy bol predikovaný stupeň odlišný viac ako jeden stupeň, nastali menej ako v 10%.

Vo Wattener Lizum boli dosiahnuté ešte lepšie výsledky ako v Západných Tatrách. Najlepšie výsledky sa blížili k 90% úspešnosti presného určenia lavínového stupňa. Pri porovnaní spracovania určených stupňov lavínového nebezpečenstva dosiahlo najlepšie výsledky spracovanie, v ktorom bol robený priemer všetkých určených stupňov pre daný deň. Tak ako aj v Západných Tatrách, tak aj vo Wattener Lizum nie je vidieť výrazný vplyv rôzneho nastavenia skrytých vrstiev. Pri rozdieloch predikovaných

a určovaných stupňov lavínového nebezpečenstva, sa rozdiely nad jeden stupeň blížili k 1%, čo sú vynikajúce výsledky. Lepšie výsledky oproti Západným Tatrám mohli byť dosiahnuté aj vďaka tomu, že vo Wattener Lizum je stupeň lavínového nebezpečenstva určovaný pre danú dolinu a nie celé pohorie ako je to aktuálne na Slovensku.

V oboch oblastiach boli výsledky ovplyvňované rovnakými situáciami. Prvá situácia, ktorú nie je možné odstrániť, je subjektivita pri určovaní stupňa lavínového nebezpečenstva. A to z dôvodu, že nie je možné zabezpečiť, aby bol stupeň lavínového nebezpečenstva určovaný denne len jedným expertom po dobu celej sezóny.

Ďalšie, čo ovplyvňuje výsledky, je nerovnomerné rozloženie stupňov lavínového nebezpečenstva. Najčastejšie určovaným stupňom je stupeň 2 a 3 a s výrazne menším zastúpením je stupeň 1 a s ešte menším je stupeň 4 a stupeň 5 má takmer nulové zastúpenie. Z dôvodu, že je nedostatočný počet dní so stupňom 1 a 4, tak pri trénovaní je nedostatok takýchto situácií a tým je menšia pravdepodobnosť, že sa neurónová sieť správne naučí na takéto dni.

V Západných Tatrách sú k dispozícii viaceré AMS, problém však je, že v AMS Hrubá kopa dochádzalo k častým výpadkom a preto sa nedalo s týmito údajmi vhodne pracovať. V prípade, že by boli k dispozícii aj údaje z tejto stanice, tak by bolo možné vylepšiť aktuálne fungovanie navrhnutého algoritmu. Okrem toho by výrazne pomohla hustejšia sieť AMS, aby bolo možné určovať stupeň lavínového nebezpečenstva pre konkrétnu dolinu a nie pre celé pohorie. Ako bolo aj vidieť z údajov z Wattener Lizum, ak je určovaný stupeň pre konkrétnu dolinu, tak aj úspešnosť algoritmu je vyššia.

#### Prínosy dizertačnej práce

Hlavným prínosom tejto práce je vytvorenie algoritmu, ktorý spracuje údaje namerané pomocou AMS do vstupných sád pre neurónové siete. Výhodou tohto spracovania je, že pracuje so základnými meteorologickými údajmi a údajmi o snehu, ktoré sú väčšinou dostupné v každom pohorí.

Ďalším prínosom je realizácia tejto práce v dvoch odlišných oblastiach, kde bolo možné overiť funkčnosť navrhnutého algoritmu pri rôznych podmienkach. Vďaka týmto rôznym oblastiam bolo možné vidieť vlastnosti navrhnutého riešenia.

V praxi má táto práca veľký prínos pre expertov, ktorí určujú stupeň lavínového nebezpečenstva. Realizáciou riešení navrhnutých v tejto práci pre konkrétne pohoria je možné zefektívniť určovanie stupňa lavínového nebezpečenstva, čo ocenili priamo v Horskej záchranej službe na Slovensku.

#### Ďalšie možnosti pokračovania

Táto práca poskytuje veľký potenciál na ďalšie pokračovanie. Po získaní všetkých údajov zo staníc v Žiarskej chate a na Hrubej kope je možné spracovanie rozšíriť o vzájomný vzťah týchto AMS.

V prípade, že by bolo možné získať údaje z viacerých sezón, tak by sa výrazne zvýšila množina dní na tréningovanie neurónovej siete.

Okrem toho je možné rozšíriť algoritmus aj na ďalšie pohoria na Slovensku a porovnať údaje pre jednotlivé pohoria, prípadne pridať aj topografické vlastnosti dolín a predikovať lavínové nebezpečenstvo pre jednotlivé svahy. Možnosti pokračovania v tejto téme sú veľké a s tým je aj predpoklad, že sa v tejto téme bude pokračovať.

Ďalšou možnosťou je rozšíriť merané parametre aj o napr. teplotu povrchu, ktorý pomáha predikovať základové lavíny. Ďalšie parametre, o ktoré by bolo možné rozšíriť spracovanie, by mohli zlepšiť úspešnosť predikcie. Rozšíriť by sa taktiež mohlo o predpoveď počasia pre daný alebo aj nasledujúci deň.

## LITERATÚRA

1. *40 years of avalanche prevention and safety in Slovakia*. Biskupič, Marek, a iní. 2012. *Advances in avalanche forecasting*. s. 12-15.
2. *Sneh a lavíny 2007/2008*. s.l. : Stredisko lavínovej prevencie, 2008.
3. *Sneh a lavíny 2015-2017*. s.l. : Stredisko lavínovej prevencie, 2018.
4. Schaerer, Peter a McClung, David. *The Avalanche Handbook 3rd Edition*. s.l. : Brand: Mountaineers Books, 2006. 978-0-89886-809-8.
5. laviny.sk. [Online] [Dátum: 6. 5 2018.] <http://www.laviny.sk/metodika-laviny/nauka-o-snehu-a-lavinach/>.
6. Tirol, Lawinenwarndienst. *Lawinen.report*. [Online] [Dátum: 6. 5 2018.] <https://lawinen.report/bulletin/latest>.
7. —. Lawinen Probleme. [Online] [Dátum: 6. 5 2018.] <https://lawinen.report/education/avp>.
8. *Die Lawine im Fokus*. s.l. : Bundesforschungszentrum für Wald, 2016.
9. *Determining the drivers for snow gliding*. Fromm, Reinhard, a iní. 2018, *Nat. Hazards Earth Syst. Sci.*, Zv. 18, s. 1891-1903.



10. *Lawinenprognose mit statistischen und selbstlernenden Verfahren im Projekt NAFTA. Schutz des Lebensraumes vor Hochwasser, Muren und Lawinen.* Kleemayer, K., a iní. 2000. Proc. Intern. Symp. Interpraevent. s. 411-422.
11. *Avalanche forecast using numerical weather prediction in Indian Himalaya.* Singh, A., Srinivasan, K. a Ganju, A. 2005, Cold Regions Science and Technology, Zv. 43, s. 83-92.
12. *Estimating the forecasting success of artificially triggering of avalanches with the combination of cluster and discriminant analysis.* Fromm, Reinhard. 2009. International Snow Science Workshop. s. 366-370.
13. *Lavíny.* Liptovský hrádok : Stredisko lavínovej prevencie, 2015.
14. Interpretácia snehových profilov. [Online] 2014. [Dátum: 6. 5 2018.] [https://issuu.com/laviny/docs/interpretacia\\_profilov](https://issuu.com/laviny/docs/interpretacia_profilov).
15. DAJAMA. *Západné Tatry.* s.l. : DAJAMA, 2010. 8089226221.
16. Hiking. *Turistická a lavínová mapa.* [Online] [Dátum: 6. 5 2018.] <https://mapy.hiking.sk/?ref=navigator>.
17. Alpenverein, Österreichischer. *Tuxer Alpen: Skitouren.* s.l. : Österreichischer Alpenverein, 2016.
18. Microstep-MIS. *Dátový list pre AMS.*
19. *Classification trees as a tool for operational avalanche forecasting on the Sewerd Highway, Alaska.* Hendrikx, Jordy, Murphy, Matt a Onslow, Terry. 2014, Cold Regions Science and Technology, Zv. 97, s. 113-120.
20. *Relating storm and weather factors to dry slab avalanche activity at Alta, Utah, and Mammoth Mountain, California using classification and regression trees.* Davis, R.E., a iní. 1999, Cold Regions Science and Technology, Zv. 30, s. 79-89.
21. *FORECASTING SNOW AVALANCHE DAYS FROM METEOROLOGICAL DATA USING CLASSIFICATION TREES; GRASDALEN, WESTERN NORWAY.* Kronholm, Kalle, a iní. Telluride, Colorado : s.n., 2006. International Snow Science Workshop.
22. *Relating meteorological parameters to glide-snow avalanche activity.* Dreier, Lisa, a iní. s.l. : Elsevier, 2016, Cold Regions Science and Technology, Zv. 128, s. 57-68.
23. *Calibration of nearest neighbors model for avalanche forecasting.* Singh, Amreek, et al. s.l. : Elsevier, 2015, Cold Regions Science and Technology, Vol. 109, pp. 33-42.

24. *A nearestneighbour model for forecasting skier-triggered dry-slab avalanches on persistent weak layers in the Columbia Mountains, Canada.* Zeidler, A. a Jameson, B. 2004, *Annals of Glaciology*, Zv. 38, s. 166–172.
25. Zeidler, Antonia. *Forecasting Skier-triggered Avalanches in the Columbia Mountains of Canada.* 2004.
26. *A nearest/neighbor model for regional avalanche forecasting.* Brabec, Bernhard a Meister, Roland. 2001, *Annals of Glaciology*, Zv. 32, s. 130-134.
27. *Recent developments of avalanche forecasting by discriminant analysis techniques: A methodological review and some applications to the Parsenn area.* Obled, Charles a Good, Walter. 92, 1980, *Journal of Glaciology*, Zv. 25, s. 315-343.
28. *Avalanche forecast with the method of nearest neighbours: an interactive approach.* Buser, O. 1983, *Cold Regions Science and Technology*, Zv. 8, s. 155-163.
29. *Two years experience of operational avalanche forecasting using the nearest neighbour method.* Buser, O. 1989, *Annual Glaciology*, Zv. 13, s. 31-34.
30. Beňušková, E. Umelé neurónové siete. [Online] [Dátum: 10. 16 2019.] <http://dai.fmph.uniba.sk/courses/ICI/References/benuskova.UNS.pdf>.
31. Kvasnička, Vladimír, a iní. *Úvod do teórie neurónových sietí.* 1997.
32. *Use of Neural Networks in Avalanche Hazard Forecasting.* Stephens, J., a iní. Utah, USA : Internation Snow Science Workshop, 1994.
33. *Artificial Neural Networks for Snow Avalanche Forecasting in Indian Himalaya.* Singh, A. a Ganju, A. Goa : s.n., 2008. Internation Conference of International Association for Computer Methods and Advances in Geomechanics.
34. *Avalanche Dynamics and Correlations in Neural Systems.* Lombardi, Fabrizio, Herrmann, Hans J. a Arcangelis, Lucilla de. 2018. *Dynamical Network States, Criticality and Cortical Function.*
35. *A Meteorological Distribution System for High-resolution Terrestrial Modeling (MicroMet).* Liston, Glen E. a Elder, Kelly. 2006, *Journal of Hydrometeorology*, Zv. 7, s. 217-234.
36. *River flow forecasting through conceptual models: Part I-A discussion of principles.* Nash, J. E. a Sutcliffe, J. V. 1970, *Journal of Hydrometeorology*, Zv. 10, s. 282-290.

37. *Simple procedures for extrapolation of humidity variables in the mountainous wester United States.* Kunkel, K. E. 1989, *Journal of Climate*, *Zv. 2*, s. 656-669.
38. *New equations for computing vapor pressure and enhancement factor.* Buck, A. L. 1981, *Journal of Applied Meteorology*, *Zv. 20*, s. 1527-1532.
39. *Measuring Snow Depth with a Terrestrial Laser Ranging System.* Jörg, Philipp, a iní. 2006. *International Snow Science Workshop*. s. 452-460.