



Středoškolská technika 2009

**Setkání a prezentace prací
středoškolských studentů na ČVUT**

Entomologie, metody umělé inteligence pro determinaci species

Autor:

Tomáš Pohl

Sexta B

Gymnázium, Brno-Řečkovice

Terezy Novákové 2

621 00 Brno

Vedoucí práce:

Prof. RNDr. Josef Havel, DrSc.

Konzultant:

Prof. RNDr. Jaromír Vaňhara CSc.

(Masarykova univerzita Brno)

Brno 2009

Prohlašuji, že jsem svou práci vypracoval samostatně a použil jsem pouze podklady (literaturu, SW atd.) uvedené v příloženém seznamu.

Nemám závažný důvod proti zpřístupňování této práce v souladu se zákonem č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon) v platném znění.

V Brně dne 1.3.2009

vlastnoruční podpis

Poděkování

Děkuji panu prof. RNDr. Josefu Havlovi, DrSc. za obětavou pomoc a podnětné připomínky, které mi při vedení mé práce poskytoval. Rovněž bych chtěl poděkovat panu prof. RNDr. Jaromíru Vaňharovi CSc. za dodání veškerého biologického materiálu a za pomoc po stránce entomologické. Chtěl bych také poděkovat Mgr. Martině Blahové, coby mé školní konzultance a Jaromíru Vaňharovi ml. za pomoc s vývojem softwaru.

Tomáš Pohl

Anotace

V první části práce byly vysvětleny základní teoretické pojmy, ve druhé byla úspěšně zvládnuta technika aplikace umělých neuronových sítí (Artificial Neural Network - ANN) pro rozpoznávání vzoru (Pattern Recognition). Byly vytvořeny 3 praktické příklady. V prvních dvou byla vyřešena otázka, jak transformovat fotografie do vstupních informací, bylo použito několika základních vzorků pro ověření a potvrzení funkčnosti umělých neuronových sítí v kombinaci s rozpoznáváním vzoru (Pattern Recognition) a u třetího příkladu klasifikace druhů pouze pomocí umělých neuronových sítí. U všech příkladů byla úspěšně vytvořena dostačující databáze s transformovanými obrázky a byla nalezena optimální architektura sítí pomocí RMS. Na této architektuře byla databáze natrénována a konec tréninkového procesu byl ověřen vložení předem nezahrnuté vstupní informace. Výsledkem celého tohoto procesu byla úspěšná determinace (určení) všech vzorků (objektů na fotografii). V poslední fázi byly započaty kroky k úspěšné determinaci fotografií hmyzu, v našem případě klasifikace pomocí fotografií muších křídel dvou druhů much. *Tachina (Servillia) ursina* a *Tachina (Tachina) grossa*. Byla úspěšně vyřešena otázka úpravy fotografie do optimálního stavu a vyřešeny základní principy redukce. Snímek byl následně úspěšně transformován na číselné hodnoty pomocí vhodného programu. Závěrem práce je shrnutí základních poznatků o aplikaci metod umělých neuronových sítí a rozpoznávání vzoru a jejich úspěšnost a použitelnost v budoucnu. Práce bude rovněž sloužit jako ojedinelá česky psaná souhrnná publikace o ANN a rozpoznávání vzoru a jejich aplikaci v praxi.

Klíčová slova

umělá inteligence, umělé neuronové sítě (Artificial Neural Networks), ANN, rozpoznávání vzoru (Pattern Recognition), určování druhů, Tachinidae, Trajan, Adobe Photoshop, digitální fotografie, křídlo, transformace, trénink, predikce, verifikace, vstup (Input), výstup (Output), skrytá vrstva (Hidden Layer), uzly

Obsah

Předmluva	7
1 ÚVOD	8
1.1 Úvod	9
1.2 Metody umělé inteligence	9
1.2.1 Úvod	9
1.2.2 Historie	9
1.2.3 Definice	10
1.2.3.1 Definice 1.	10
1.2.3.2 Definice 2.	10
1.2.3.3 Alternativní definice	10
1.3 Umělé neuronové sítě (ANN)	11
1.3.1 Princip	11
1.3.2 Přenosové funkce	12
1.3.3 Proces: trénink, verifikace a predikce	12
1.3.4 Výhody a nevýhody	13
1.3.5 Využití	13
1.4 Rozpoznávání vzoru (Pattern Recognition)	14
1.4.1 Princip	14
1.4.2 Využití PR	14
1.5 Využití identifikace hmyzu pomocí ANN a PR	15
1.5.1 Zemědělství	15
1.5.2 Klasifikace jedovatého hmyzu či jiných zvířat	15
1.5.3 Projekt Bio-Protection na Novém Zélandu	16
2 PRAKTICKÉ PŘÍKLADY	17
2.1 Úvod	18
2.2 Příklad I: Rozpoznávání geometrických obrazců	18
2.2.1 Úvod	18
2.2.2 Vytvoření databáze	18
2.2.3 Transformace - binární kód	19
2.2.4 Architektura & trénink	21
2.3 Příklad II: Rozpoznávání písmen	22

2.3.1 Úvod	22
2.3.2 Využití - ověřovací kód & metoda OCR	22
2.3.3 Vytvoření databáze	23
2.3.4 Transformace	24
2.3.5 Trénink	24
2.4 Příklad III: Tachinidae	25
2.4.1 Úvod	25
2.4.2 Materiál (data) a software	25
2.4.3 Postup	25
2.4.4 Měření vzdáleností na křídle	26
3 APLIKACE NA DIGITÁLNÍ FOTOGRAFIE KŘÍDEL	27
3.1 Úvod	28
3.2 Použitá data (databáze) + software & hardware	28
3.3 Úprava fotografie do optimálního vzhledu	28
3.3.1 Úvod	28
3.3.2 Postup úpravy fotografie	29
3.3.2.1 Původní fotografie	30
3.3.2.2 Krok č.1 - Oříznutí	30
3.3.2.3 Krok č.2 - Převedení na stupně šedi	31
3.3.2.4 Krok č.3 - Aplikace efektu Curves	32
3.3.2.5 Krok č.4 - Nastavení jasu a kontrastu	32
3.3.2.6 Krok č.5 - Ideální redukce fotografie	33
3.4 Transformace digitálních dat fotografie	35
3.4.1 Princip	35
3.4.2 Program pro transformaci fotografie	35
3.4.3 Postup	36
4 ZÁVĚRY A SHRNUÍ	38
4.1 Výhody identifikace hmyzu pomocí ANN a PR	39
4.1.1 Výhody oproti práci entomologa	39
4.1.2 Výhody oproti molekulárnímu rozboru	39
4.2 Shrnutí	39
Epilog	40
Seznam použité literatury a internetu	41

Předmluva

Jedním ze základních úkolů v biologii a tedy i v entomologii, ale i v jiných oblastech přírodních věd je klasifikace druhů. Toto určování druhů či klasifikace v přírodních vědách se většinou provádí podle dobře pozorovatelných znaků, charakteristických rysů. Např. tvar, barva atd. V přírodních vědách lze jmenovat snad 3 nejvýznamnější příklady: Charles Darwin, Carl Linné a Johan Gregor Mendel.

Tyto práce vedly k systematické biologii, tvorbě učebnic a klíčů na rozpoznávání biologických objektů atd. S rozvojem výpočetní techniky a umělých neuronových sítí dochází v posledních letech k revoluci a tyto tradiční metody jsou nahrazovány metodami využívající i metodu počítačů.

Pokud bych měl svoji středoškolskou odbornou činnost shrnout několika málo slovy, vysvětlil bych ji asi takto. Moje práce má za úkol vypracovat velmi ojedinělou a užitečnou metodu založenou na rozpoznávání digitálních fotografií křídel pro určování blízkých a podobných druhů much. I když o tom možná nevíte, tato metoda se hojně využívá v jiných oborech jako např. medicína (rozpoznávání melanomů), kriminalistika (otisky prstů aj.), vojenství (zpracování satelitních snímků aj.) atd., avšak pro určování druhů hmyzu jen v několika málo případech a pro určování much nikdy.

K problematice umělé inteligence pro determinaci druhů neexistuje téměř žádná literatura v českém jazyce. V angličtině bylo již sepsáno velké množství kvalitních článků, ale pokud se k nim chce laik dostat, není to tak jednoduché. Proto není od věci využívat tuto práci rovněž jako komplexní českou publikaci pojednávající o základních teoretických faktech k tématu a nakonec o samotné aplikaci této metody v praxi.

Cílem mé práce je vyvinout za pomoci přírodovědecké fakulty Masarykovy univerzity metodu využívající rozpoznávání vzoru (Pattern Recognition) a umělých neuronových sítí pro určování druhů much. Přírodovědecká fakulta používá metody umělých neuronových sítí pro určování hmyzu a je v tomto oboru jedinečná v rámci ČR, ale využití Pattern Recognition je další krok k jednodušší, rychlejší a modernější práci.

Doufám, že tato práce poskytne čtenářům dostatečné množství informací o využití této zajímavé metody.

Autor

1

ÚVOD

- Metody umělé inteligence
- Umělé neuronové sítě (ANN)
- Rozpoznávání vzoru (Pattern Recognition)

1.1 Úvod

V úvodu bych rád popsal několik základních teoretických pojmů, které jsou nezbytné pro pochopení celé práce. Chtěl bych čtenáře seznámit s umělou inteligencí, umělými neuronovými sítěmi a metodou rozpoznávání vzoru (Pattern Recognition). Čtenář poté snadněji porozumí obsahu celé práce.

1.2 Metody umělé inteligence

1.2.1 Úvod

Inteligence je vlastností některých živých organismů, vznikla a vyvíjela se v průběhu dlouhého časového intervalu a dnes umožňuje některým živým organismům efektivně reagovat na složité projevy prostředí a aktivně je využívat ve svůj prospěch, k dosažení svých cílů.

Souběžně s rozvojem techniky si lidé kladli otázku, zda lze i u uměle vytvořených systémů dosahovat reakcí a celkového chování, kterému bychom u živých organismů dali přívlastek inteligentní. Tyto otázky byly řešeny již dlouho před vznikem prvních elektronických počítačů pomocí tehdejší filosofie a psychologie.

1.2.2 Historie

Otázku "Mohou stroje myslet?" řešili již v 17. století filosofové jako Descartes (Cartesius), Pascal, Hobbes a později La Metrie. Jejich závěry byly čistě filosofické, byly zaměřeny na otázky, zda mohou stroje myslet, ne, jak toho dosáhnout.

V první polovině 19. století vědecky působila v Anglii Ada Byron, Lady Lovelace (1815-1852). Byla dcerou básníka George Gordona Byrona, ale inklinovala spíše k matematice. V roce 1833 Charles Babbage sestrojil mechanický počítač Analytical Engine. Ada Byron reagovala na jeho myšlenky a později přeložila Babbagovy přednášky (které vedl v Itálii). Babbage jí navrhnul, aby k překladu přidala svůj výklad (který se ukázal být třikrát delší, než vlastní přednášky). V něm prohlásila, že počítače budou komponovat hudbu, vytvářet umělecká díla a budou používány jak pro vědecké, tak pro praktické účely. Rovněž sestavila plán, jak by mohl Analytical Machine počítat Bernoulliho čísla, čímž napsala první počítačový program.

S růstem možností výpočetní techniky od 30. let XX. století se objevovaly a objevují snahy o automatizované řešení problémů tak, jak by je řešil člověk s použitím své inteligence. Postupně byly navrhovány a ověřovány metody, postupy a algoritmy, umožňující napodobovat určité hledisko inteligentního chování.

1.2.3 Definice

Všechny postupy a algoritmy, které v konečném důsledku vedou k napodobování projevů inteligentního chování člověka jsou předmětem zkoumání mladé vědní disciplíny - Umělé inteligence (dále UI) - (angl. artificial intelligence).

1.2.3.1 Definice 1.

Marvin Minsky tvrdí, že "... umělá inteligence je věda o vytváření strojů nebo systémů, které budou při řešení určitého úkolu užívat takového postupu, který - kdyby ho dělal člověk - bychom považovali za projev jeho inteligence." (1967)

Tato definice vychází z Turingova testu¹. Vyplývá z ní, že úlohy jsou tak složité, že i u člověka by vyžadovaly použití inteligence. Otázkou však je, jaké vlastnosti má složitost a "inteligentní" řešení?

1.2.3.2 Definice 2.

E. Richová se domnívá, že "... umělá inteligence se zabývá tím, jak počítačově řešit úlohy, které dnes zatím zvládají lidé lépe." (1991)

Tato definice se bezprostředně váže na aktuální stav v oblasti počítačových věd a je možno očekávat, že se v budoucnosti bude ohnisko této vědy posouvat a měnit. Nevýhodou této - jinak velmi výstižné - definice je fakt, že nezahrnuje úlohy, které dosud neumí řešit počítače, ale ani člověk.

1.2.3.3 Alternativní definice

1. UI je označení uměle vytvořeného jevu, který dostatečně přesvědčivě připomíná přirozený fenomén lidské inteligence
2. UI označuje tu oblast poznávání skutečnosti, která se zaobírá hledáním hranic a možností symbolické, znakové reprezentace poznatků a procesů jejich nabývání, udržování a využívání
3. UI se zabývá problematikou postupů zpracování poznatků - osvojováním a způsobem použití poznatků při řešení problémů

Umělá inteligence je interdisciplinární vědou, která nemá pevně vymezený předmět zkoumání ani teoretický základ - jde spíše o soubor metod, teoretických přístupů a algoritmů, sloužících k řešení velmi složitých úloh. Je typické, že výsledky řešení dílčích problémů UI slouží buď jiným vědním disciplínám k aplikaci, nebo jako základ k formování nových vědních disciplín. (např. učící algoritmy se staly součástí teorie automatizovaného řízení, rámcová reprezentace poznatků se odrazila v objektivě orientovaném programování apod.)

¹ **Turingův test** probíhá tak, že do oddělených místností umístíme jednak testujícího, jednak předmět zkoumání (např. počítač s příslušným programem) a nějakého dalšího člověka. Testující poté klade otázky v přirozené řeči a předává je do druhé místnosti, kde je zodpoví buď počítač, nebo druhý člověk (což se rozhodne náhodně). Odpovědi jsou předávány zpět testujícímu (samozřejmě v nějaké neutrální podobě, např. vytištěné na papíře). Pokud testující nedokáže rozpoznat, jestli komunikuje se strojem, nebo s člověkem, pak tato umělá inteligence splňuje Turingův test.

1.3 Umělé neuronové sítě (ANN)

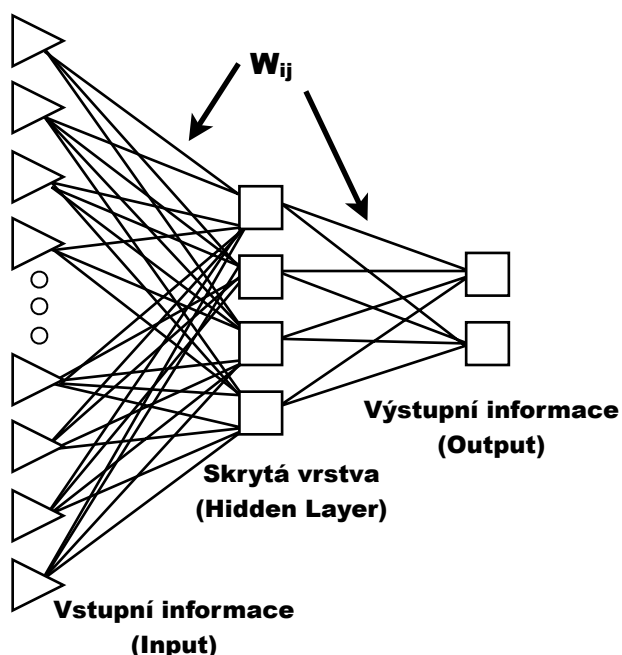
1.3.1 Princip

ANN (Artificial Neural Network) reprezentuje sofistikovaný výpočetní modelový nástroj, který může být použit k vyřešení rozsáhlých, rozmanitých a komplexních problémů. Atraktivita ANN v biologii spočívá v jejich schopnosti učit se a/nebo modelovat velmi komplexní systémy, které umožňují využití coby nástroj pro klasifikaci. Proto je jejich aktuální potenciál v tomto vědním oboru opravdu vysoký.

Velký rozdíl mezi obvyklými počítačovými programy a ANN je fakt, že běžné programy mohou řešit pouze takové úkoly, pro které jsou speciálně sestaveny, zatímco ANN je druh učícího se nástroje, který může být naučen téměř čemukoliv.

ANN je výpočetní model tvořený určitými číselnými hodnotami, umělými neurony nebo uzly spojenými koeficienty (váhami = weights; w_{ij}), které představují neuronovou strukturu.


Existuje mnoho neuronových architektur. Jedna z nejběžnějších je "feedforward supervised neural network of multi-layer perceptrons" (MLP). MLP je konvenčně zkonstruovaná síť se třemi nebo více vrstvami, tzn. vstupní informace (Input), výstupní informace (Output) a skrytá vrstva (Hidden Layer) (Obr. 1). Každá vrstva má rozdílný počet uzlů. Vstupní vrstva přijímá vkládané informace, přičemž každý uzel této vrstvy představuje jednu vstupní informaci. Skrytá vrstva zpracovává informace z vrstvy vstupní, zatímco výstupní vrstva je pozorovatelná odpověď systému.



Obr. 1: Příklad jedné z možných architektur umělé neuronové sítě (ANN).

Vstupy (*inputs*) násobeny váhovými spoji (w_{ij}) jsou nejprve sečteny a následně transformovány skrz přenosovou funkci (1.3.2), abychom získali výstup (*output*). Určení vhodného počtu skrytých vrstev a počtu uzlů v každé této vrstvě je nejkritičtější momentem v tvoření umělé neuronové sítě.

$$Y = S \left(\sum_{i=1}^N (w_i X_i) - \Theta \right)$$



Obr. 2: Matematické vyjádření ANN, kde x_i jsou vstupy neuronu, w_i jsou synaptické váhy, Θ je práh, $S(x)$ je přenosová funkce neuronu (někdy aktivační funkce), Y je výstup neuronu.


1.3.2 Přenosové funkce

Skoková přenosová funkce vrací pro vstup menší než daná mez nulu, pro větší vrací jedna. $f(x) = 0$ pro $x < \Theta$ a $f(x) = 1$ pro $x \geq \Theta$


Sigmoidální přenosová funkce je ve tvaru $f(x) = \frac{1}{1 + e^{-kx}}$. Její hodnoty se blíží nule v mínus nekonečnu a jedničce v nekonečnu. Pro nulu je hodnota 0,5. Výhodou sigmoidální přenosové funkce oproti skokové je existence rozumné derivace v každém bodě.

Přenosová funkce hyperbolické tangenty je ve tvaru $f(x) = \frac{2}{1 + e^{-kx}} - 1$. Její hodnoty se blíží -1 v minus nekonečnu a jedničce v nekonečnu. Pro nulu je hodnota 0.


Přenosová funkce radiální báze je ve tvaru $f(x) = e^{-kx^2}$. Její hodnoty se blíží nule v minus nekonečnu a nule v nekonečnu. Pro nulu je maximální hodnota 1.




Obr. 3: Skoková přenosová funkce.



Obr. 4: Sigmoidální přenosová funkce.



Obr. 5: Přenosová funkce hyperbolické tangenty.



Obr. 6: Přenosová funkce radiální báze.

1.3.3 Proces: trénink, verifikace a predikce

Používání ANN se skládá ze dvou základních kroků. "Trénink" a "předpovídání" neboli predikce. Trénink se skládá nejdříve z definice vstupních a výstupních hodnot. Obvykle je nezbytné vkládaná data vhodně upravit a normalizovat tak, aby je byla síť schopna pojmout. Tato data

poté tvoří tzv. "tréninkový set". V této fázi jsou hledány optimální struktury a váhové koeficienty pro dané informace. Trénink je považován za kompletní, jakmile neuronové sítě dosáhnou požadované statistické přesnosti a produkují vhodné výstupy vůči vstupním datům. Vhodné kritérium pro nalezení správné síťové struktury a tudíž zastavení tréninkového procesu, je minimalizace kvadratického průměru chyby (root mean square error = RMS).

$$\text{RMS} = \sqrt{\frac{\sum_{i=1}^N \sum_{j=1}^M (y_{ij} - out_{ij})^2}{N \times M}}$$

Kde y_{ij} je elementem matice ($N \times M$) pro tréninkový set a out_{ij} je elementem pro výstupovou matici ($N \times M$) kde N je počet proměnných v matici a M je počet vzorků.

V okamžiku, kdy síť dosáhne požadovaného výkonu během tréninku, je důležité zkontrolovat, jak si síť poradí s daty, která předtím "neviděla", neboli databáze (vstupní vrstva) je neobsahovala. Tomuto procesu říkáme "ověřování" (verification). Toto testování je nutné k ujistění se, že síť nemá tréninkový set pouze namemorovaný, ale že se naučila zahrnout obecné vzory během aplikace. V této chvíli jsou do sítě vložena další vstupní data, aby je síť zhodnotila a předpověděla výstupy. V tomto případě jsou výstupy již známy, ale nejsou síti předloženy. Předpovězené výstupní hodnoty jsou porovnány s hodnotami experimentálními, které jsme získali jiným způsobem klasifikace, abychom viděli, jak dobře síť pracuje. Pokud systém neposkytuje racionální výstup, tréninková perioda ještě není u konce, neboť síť sice dokáže data modelovat, ale nedokáže je předpovědět. Jakmile proběhne ověření dat úspěšně, jsou ve finální fázi neznámá data zhodnocena a předpovězena. Klasifikace neznámých dat je u konce.

1.3.4 Výhody a nevýhody

- ✓ ANN může provést výpočet úkolů, které lineární program nedokáže.
 - ✓ Pokud nějaký prvek v ANN selže, dokáže přesto pokračovat bez jakéhokoliv problému.
 - ✓ Neuronová síť se učí a nemusí být přeprogramována.
 - ✓ Může být prováděna při jakékoliv aplikaci.
- Aby fungovala jak má, vyžaduje ANN tréninkový proces.
 - Architektura ANN je odlišná od architektury mikroprocesorů, proto musí být napodobována.
 - Vyžaduje vysoký čas zpracování pro velké neuronové sítě.
 - Existují různé architektury, což vyžaduje různé typy algoritmů.

1.3.5 Využití

Umělé neuronové sítě mají obrovský potenciál a jejich využití je opravdu rozsáhlé. S nástupem "rychlých" počítačů dochází k jejich zapojování i do oborů, kde si dříve člověk vystačil sám a vykonávají zde i úkony, které lidé provádí již staletí, ovšem daleko sofistikovanější, přesnější, ale především jednodušší a rychlejší cestou. Díky integraci počítačů do oborů jako je biologie, chemie, ale i entomologie aj., zjistili vědci spoustu nových skutečností, které jim byly bez možnosti využití výpočetní techniky dodnes skryty. Využití nachází např. v chemii, biochemii, stejně jako v biologii, mikrobiologii, ekologii, hydrobiologii, entomologii a dokonce i ve vyšetřovacích metodách. Využití ANN v taxonomii je poměrně nové i přesto, že v této disciplíně zaznamenávají velký úspěch s vysokou přesností.

1.4 Rozpoznávání vzoru (Pattern Recognition)

1.4.1 Princip

Pattern Recognition v českém překladu znamená doslova "rozpoznávání vzoru". To o této metodě hodně vypovídá, a je to v podstatě její definice. Pattern Recognition je metoda, která umožňuje rozpoznat objekt na fotografii, případně videu.

Pokud máme např. fotografii, na které je zachycen dětský pokoj plný různých objektů, jako jsou obrazy, nábytek, bytové doplňky atd. a v tomto pokoji sedí dva lidé, lidské oko a mozek okamžitě pozná lidské obličej a rozliší je od okolí. Pro počítač je digitální fotografie pouze změř různě barevných pixelů, v podstatě soubor různých čísel. A právě metoda Pattern Recognition umožňuje objekty na fotografii rozlišit.



Obr. 7: Pokoj plný různých předmětů, Pattern Recognition ale dokáže rozlišit jednotlivé objekty (zdroj: mojstyl.sk).

1.4.2 Využití PR

Využití metody Pattern Recognition je opravdu rozsáhlé. Největší zastoupení má v oborech jako je kriminalistika, medicína či vojenská technologie, ale poslední dobou se dostává i do našeho každodenního života.

O otiscích prstů v kriminalistice slyšel jistě téměř každý. Málokdo však ví, že se při porovnávání nalezeného otisku s databází využívá metody právě Pattern Recognition. Databáze obsahuje tisíce až milióny otisků různých osob. Pokud se na otisk prstu podíváme z grafického hlediska, jedná se pouze o soubor černých čar na bíle ploše, resp. soubor bílých a černých pixelů. Polohy těchto pixelů se porovnávají s polohou pixelů na vstupním vzorku, dokud program nenalezne shodu.

V oblasti medicíny nalezneme spoustu případů, kdy je metoda Pattern Recognition využívána. Já bych chtěl jmenovat pouze jednu z nich, o to je ale důležitější. Rozpoznávání melanomů. Celá procedura je velmi jednoduchá. Máte-li na svém těle znaménko či skvrnu, můžete se nechat vyšetřit. Vyšetření probíhá následujícím způsobem. Na podezřelou skvrnu či znaménko je přiložena kamera. Ta postižené místo vyfotografuje, a pořízený snímek „prožene“ databází, která je tvořena obrovskou sbírkou benigních a maligních vzorků. Fotografie je metodou Pattern Recognition porovnána s touto databází a výstupní informací je „ano“ či „ne“, resp. „je melanom“, „není melanom“.

1.5 Využití identifikace hmyzu pomocí ANN a PR

To, co je na této práci možná nejdůležitější, je její potencionální využití. Možná si během čtení tohoto dokumentu říkáte k čemu to vlastně všechno je, proč věc, která funguje nahrazovat jiným způsobem? Důvod je jednoduchý.

1.5.1 Zemědělství

Představme si např. následující situaci. Farmář vlastní rozsáhlá pole, na kterých pěstuje rostliny. Tato práce živí nejen jeho, ale i spoustu dalších lidí, kterým farmář rostliny prodává. Jednoho dne ale přijde katastrofa a jeho úrodu napadne neznámý druh hmyzu, který celá pole rychle likviduje. Aby zachránil svoji úrodu, musí co nejdříve daný hmyz identifikovat, aby proti němu zasáhl těmi správnými prostředky. Pokud bychom zůstali u metod starých a dodnes používaných, byl by zřejmě farmář v koncích a o svá pole by přišel, protože než by někdo hmyz určil, rostliny by byly zlikvidovány. Farmář by musel nejprve zavolat entomologa, který by na místo musel přijet, odebrat vzorky jedinců, které by potom několik dní určoval, a aby si byl jist, provedl by ještě molekulární rozbor. Dny uplynuly a úroda je pryč. Pokud bychom ale umožnili využít farmáři metody ANN a Pattern Recognition, proces by se velmi zkrátil a on by měl ještě dostatek času své rostliny zachránit. Jednoduše by jednoho jedince chytil, vyfotil jeho křídlo a mobilním telefonem (MMS), případně e-mailem by fotografii odeslal příslušným institucím. Do několika minut by dostal odpověď, o jaký druh se jedná, případně jak se ho zbavit.

1.5.2 Klasifikace jedovatého hmyzu či jiných zvířat

Další situace která může nastat, je snad ještě závažnější než příklad předcházející. Pomocí klasifikace hmyzu prostřednictvím kombinace umělých neuronových sítí a rozpoznávání vzoru můžeme zachránit nejen lidský majetek či úrodu, ale i lidské životy.

Je známo obrovské množství jedovatých druhů hmyzu a velká část populace se mezi těmito jedinci pohybuje každý den. Není ojedinělé, když hmyz člověka napadne a svým kousnutím způsobí např. silnou alergickou reakci, v horším případě může dojít dokonce i k úmrtí člověka.

Jakmile takováto situace nastane, je životně důležité, aby byla co nejrychleji člověku podána vhodná protilátka. Každý hmyz má ovšem jiný druh jedu a tudíž je i protilátka u každého jedince rozdílná. Pacient je odvezen do nemocnice (v lepším případě), a doktoři se mohou spoléhat pouze na výpověď pacienta a na základě jeho výpovědi určit pravděpodobný druh hmyzu, po-
tažmo i protilátku. Pacient však není entomolog, a jeho popis může být zavádějící, nepřesný a matoucí. Je tedy nutné pacientovi podat více protilátek najednou. Tím ale opět riskujeme alergickou reakci na jednu z protilátek, nebo se dokonce ona protilátka v této směsi nemusí ani vyskytovat.

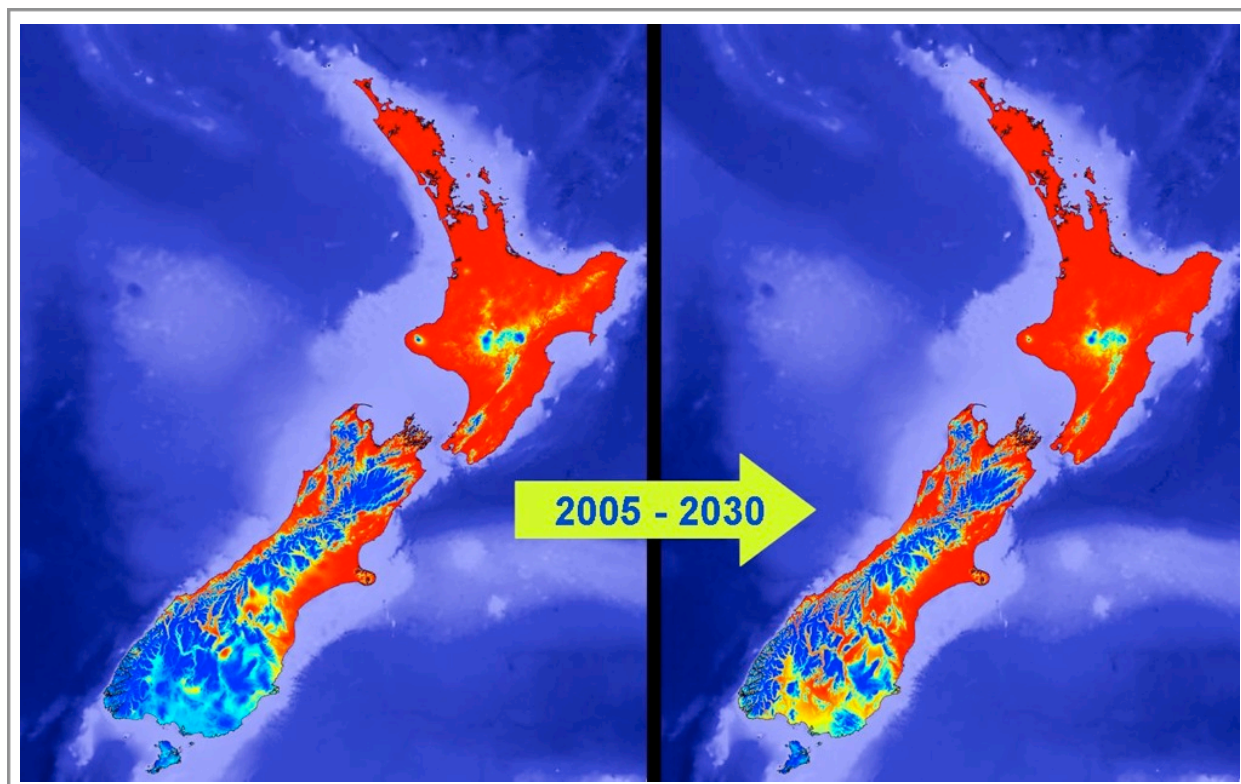
Pokud by ovšem měli lékaři k dispozici rozsáhlou databázi jedovatých druhů hmyzu, situace by byla jednodušší a bylo by zachráněno mnoho životů. V praxi by to vypadalo asi takto. Jakmile je člověk uštknut nebo kousnut jedovatým hmyzem, vyfotografuje tohoto jedince. Již v dnešní době je naprosto běžné, že sebou nosíme mobilní telefony se zabudovaným digitálním foto-

aparátem, a v budoucnu budou fotoaparáty ještě dokonalejší a telefony v našich kapsách ještě běžnější. Pokud bude databáze lékařů dostatečně obsáhlá, postačí např. pavouka, hada, šтира (i když se nejedná přímo o hmyz, ale pokud bude databáze obsahovat i tyto vzorky, nebude nic bránit určování i jiných zvířat jako jsou členovci či plazi) vyfotografovat sedícího na zemi, nebo vzor na hadově těle a metoda umělých neuronových sítí a rozpoznávání vzoru pomůže lékařům jedovatého jedince určit. Pokud na to bude systém připraven, bylo by možné fotografii odeslat MMS, a lékaři by s protilátkou již přijeli na místo nehody.

1.5.3 Projekt Bio-Protection na Novém Zélandu

Jeden z novozélandských projektů *Bio-Protection (Bioprotection science for New Zealand)* je zářným příkladem využití neuronových sítí a jejich užitečnosti pro lidskou společnost. Tento projekt se soustředí na hledání nových, nepesticidních a udržitelných řešení, která chrání novozélandské rostlinné, produktivní ekosystémy před hrozbou škůdců, chorob a plevelů. To má zásadní význam pro budoucí vývoj ekonomiky, především v souvislosti s rozrůstající se diverzifikací² obchodu, cestovního ruchu a životního prostředí.

Dr. Sue Worner z Lincolnovi univerzity je vedoucím tohoto projektu. On a jeho tým používá umělé neuronové sítě k získání dalších informací o invazi škodlivých druhů. Dosáhli toho identifikací proměnných, které nejlépe vysvětlují současné druhové rozšíření a využívá tyto informace k předpovězení přítomnosti v oblastech, kde se tyto druhy běžně nevyskytují.



Obr. 8: Mapa zobrazuje rozšíření škůdců na Novém Zélandu v roce 2005 a jejich potencionální rozšíření v roce 2030 (zdroj: bioprotection.org.nz).

² **Diverzifikace** znamená rozrůžňování, strategii podnikání, která se snaží snižovat rizika tím, že se nespolehá na jediný produkt, nýbrž rozděljuje své aktivity do různých oblastí, svá aktiva do různých firem, měn a podobně.

2

PRAKTICKÉ PŘÍKLADY

- Rozpoznávání geometrických obrazců
- Rozpoznávání písmen latinské abecedy
- Tachinidae

2.1 Úvod

Ve druhé části mé práce budu prezentovat tři základní praktické příklady, smyslem kterých je, aby čtenář snáze pochopil princip fungování metody umělých neuronových sítí a metody Pattern Recognition. Jsou zde vysvětleny základní postupy a principy od jednoduších k složitějším.

2.2 Příklad I: Rozpoznávání geometrických obrazců

2.2.1 Úvod

V prvním praktickém příkladu si ukážeme, jak se chystá databáze a jak funguje metoda ANN. Tento příklad je velice jednoduchý a jeho provedení je nenáročné. Doufám, že většina čtenářů velmi dobře pochopí fungování programu a porozumí základům pro metodu Pattern Recognition.

2.2.2 Vytvoření databáze


Jako ukázka budou nevhodnější dva vzorky. Aby byla práce co nejjednodušší, vybral jsem si dva geometrické obrazce. Čtverec a obdélník. Jelikož jde jen o malou ukázkou, postačí našemu účelu pouze čtvercová síť 10x10. Každý ze čtverečků představuje 1 px. Máme tedy před sebou pomyslný obrázek o rozlišení 100 px.

Pokud si představíme, že někdo na kousek papíru nakreslí čtverec, lidský mozek během několika mikrovteřin pozná, že se jedná o čtverec. Pokud znovu nakreslíme stejný čtverec do jiné části tohoto papíru, opět rychle a bezpečně poznáme čtverec, protože se nic nemění tím kde je nakreslený, pořád je to pro nás čtverec. Počítači musíme ovšem takovou informaci nadefinovat, resp. zahrnout ji do jeho databáze čtverců.

To stejné platí o jeho velikosti. Čtverec je pro lidské oko a mozek stále čtvercem, ať je jakékoliv velikosti. Pro počítač to ovšem opět není samozřejmostí a je proto nezbytné, abychom mu nadefinovali i různé velikosti určovaného objektu.

Proto je potřeba si nachystat několik různých poloh a velikostí od každého čtverce a obdélníku jako je vidět na obrázku č. 9.


Aby program fungoval správně a dokázal vše bez chyby určit, musí být databáze dostatečně obsáhlá. V našem případě postačí 20 různých příkladů čtverců a obdélníků. Musíme nachystat různé polohy a velikosti těchto obrazců. Vzhledem k jednoduchosti, můžeme si databázi nakreslit pouze na papír nebo připravit např. v programu Microsoft Excel.



Obr. 9: Čtyři různé způsoby zakreslení různých poloh a velikostí čtverce a obdélníku pro vytvoření databáze.

2.2.3 Transformace - binární kód

Protože nemůžeme do sítě vkládat celé obrázky, je potřeba ho transformovat na číselné hodnoty. Jakmile máme databázi připravenou, převedeme obrázek na binární kód³. Místo prázdných polí dosadíme nulu a místo polí zaplněných dosadíme jedničku a celou tuto číselnou řadu zapíšeme do jednoho řádku. Vznikne nám tedy 20 řádků jedniček a nul, přičemž každý řádek reprezentuje jeden vzorek. Výsledný zápis obrázku jednoho ze čtverců z Obr. 9 vypadá tedy takto:



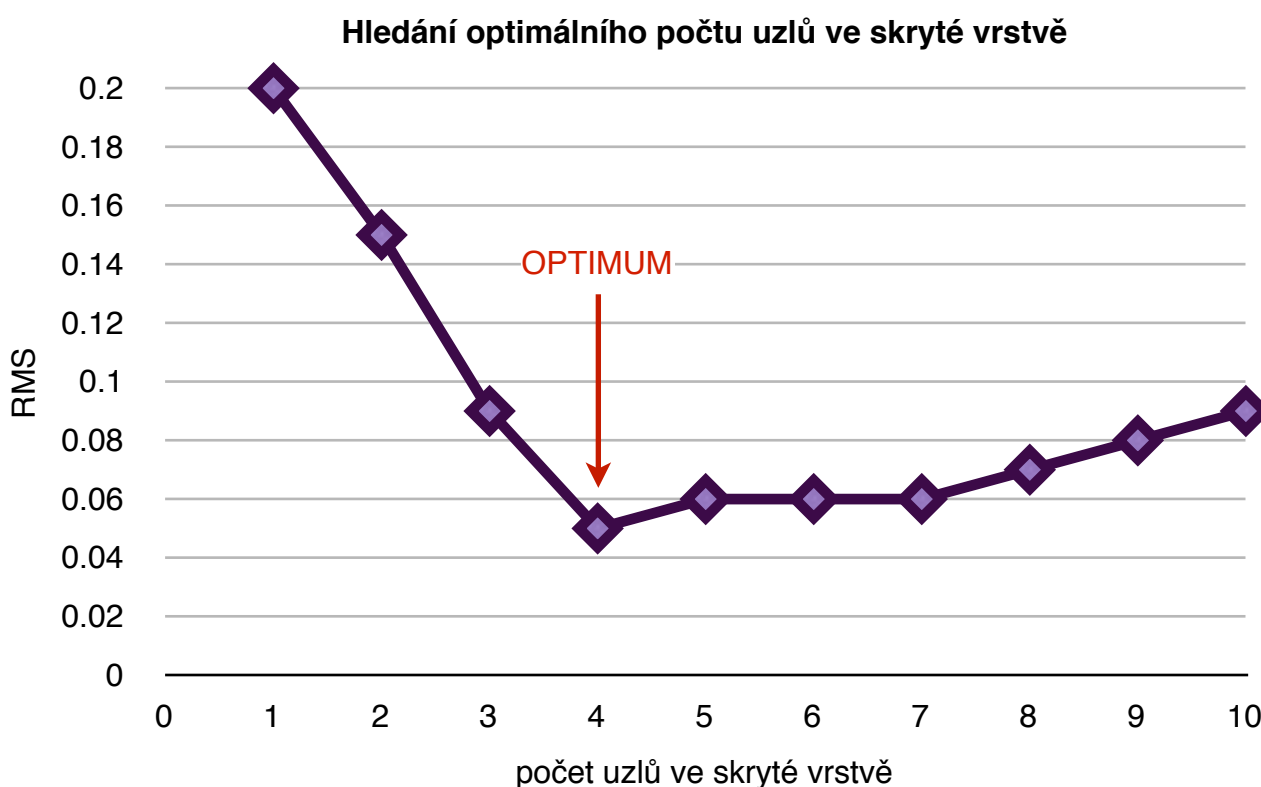
Obr. 10: Převedení černého čtverce v 100 pixelové síti na binární kód. Bílá = 0; černá = 1.

3 **Dvojková soustava (Binární soustava)** je číselná soustava, která používá pouze dva symboly - nejčastěji 0 a 1. Dvojková soustava je poziční číselná soustava mocnin čísla 2. Používá se ve všech moderních počítačích, neboť její dva symboly (0 a 1) odpovídají dvěma stavům elektrického obvodu (vypnuto a zapnuto).

2.2.4 Architektura & trénink

Každý vzorek jsme převedli na řadu jedniček a nul. Tím jsme získali jednoduchou databázi, neboli vstupní informace (přesně 20 vstupních informací). Pokud nyní chceme tyto geometrické obrazce pomocí neuronové sítě determinovat, je nutné vytvořit optimální architekturu sítě pro konkrétní databázi a celou ji na této síti natrénovat.

Jak nalézt vhodnou architekturu sítě? Co se týče počtu skrytých vrstev, můžeme již předem říci, že vzhledem k jednoduchosti vzorků a potažmo celé databáze postačí síť s pouze jednou skrytou vrstvou. Důležité je ovšem říci, kolik má tato vrstva obsahovat uzlů (1.3.1). Jednoduchou zkouškou různých počtů těchto uzlů od 0 až po 10 (více nemá smysl) a měřením RMS (1.3.3) získáme graf (Obr. 12), kde jsme schopni určit optimální počet uzlů, tedy bod v grafu, kde je RMS nejnižší. Tento počet je tedy nejvhodnějším pro architekturu naší sítě. Výsledkem jsou 4 uzly.



Obr. 12: Graf pro nalezení ideálního počtu uzlů ve skryté vrstvě.

Po nalezení vhodné stavby systému můžeme zahájit tréninkový proces (1.3.3). V našem případě se jako nejvhodnější jeví nastavení 1000 epoch během jedné periody. Celý cyklus byl zopakován 5x a proces trénování byl po těchto pěti cyklech ukončen.

Po dosažení nové vstupní informace, která se nevyskytuje v databázi, byla síť schopna tento objekt identifikovat (předpovědět). Celý systém pro určování jednoduchých geometrických objektů, který jsme vytvořili funguje se 100% úspěšností.

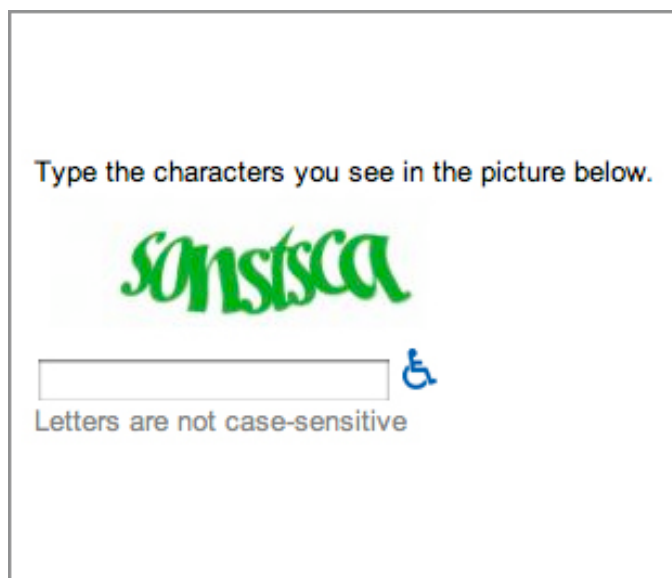
2.3 Příklad II: Rozpoznávání písmen

2.3.1 Úvod

Ve druhém praktickém příkladu nahradíme jednoduché obdélníky a čtverce složitějšími znaky latinské abecedy. Princip bude úplně stejný jako u předchozího příkladů. Rozdílem bude pouze složitost znaku a složitější čtvercová síť. U praktického příkladu č. 1 šlo pouze o pochopení principu fungování ANN, kdežto tento příklad je o krok blíže praktickému využití (viz níže).

2.3.2 Využití - ověřovací kód & metoda OCR

Možná jste někdy absolvovali nějakou internetovou registraci, při které bylo potřeba zadávat kód z obrázku a kód na tomto obrázku byl napsán velmi nezvykle, pokrouceně a sotva čitelně. Je to právě z tohoto důvodu, aby nebyl normálně čitelný text dekódován automatickými roboty a aby měla např. firma jistotu, že registraci provádí skutečný člověk.



Obr. 13: Příklad ověření registrace při vytvoření účtu emailové služby Gmail.



Obr. 14: Příklad potvrzení odeslání sms přes službu Vodafone: Poslat SMS.

Dalším využitím této metody je metoda OCR, neboli optické rozpoznávání znaků (Optical Character Recognition), která pomocí scanneru⁴ umožňuje digitalizaci tištěných textů, s nimiž pak lze pracovat jako s normálním počítačovým textem.


Počítačový program převádí obraz buď automaticky nebo se musí naučit rozpoznávat znaky. Převodný text je téměř vždy v závislosti na kvalitě předlohy třeba podrobit důkladné korektuře, protože OCR program nerozezná všechna písmena správně. OCR - zpracování textu z tištěné do elektronické podoby je použitelné pro všechny tištěné výstupy z laserových, inkous-

⁴ **Scanner**, skener (anglicky scanner, výslovnost [skennr], někdy též nesprávně [skener]; doslovný překlad snímač) je hardwarové vstupní zařízení umožňující převedení fyzické 2D nebo 3D předlohy do digitální podoby pro další využití, většinou pomocí počítače.


tových, termosublimačních a jehličkových tiskáren a samozřejmě pro předlohy vytištěné knihtiskem. U nevhodných předloh např. špatně vytištěných jehličkových tiskáren nebo dohromady spojených písmen se z časového hlediska vyplatí spíše text přepsat.

2.3.3 Vytvoření databáze

Vzhledem k tomu, že tento příklad uvádím pouze jako ukázkou využití metody umělých neuronových sítí (ANN), vybral jsem pouze dvě písmena. Písmeno "A" a písmeno "X". Jde jen o další ukázkou, proto postačí čtvercová síť o rozlišení 50x50.



Obr. 15: Ukázka tří různých poloh písmene "A" včetně nedokonalých podob (2. a 3. ukázka).



Obr. 16: Ukázka tří různých poloh písmene "X" včetně nedokonalých podob (2. a 3. ukázka).


Je velmi důležité si uvědomit, že pokud by měl být tento příklad proveden v praxi v jeho dokonalejší podobě, je nutné vzít v úvahu nejen několik různých pozic, ale i nedokonalost znaku. Například kratší nožička u písmene "A" atd. Abychom tuto situaci nasimulovali, zahrneme do databáze i několik nedokonalých variant těchto znaků. Při využívání rozpoznávání písmen v praxi je zahrnutí nedokonalostí do databáze velmi důležité a nezbytné. Pokud se vrátíme k OCR, uvědomíme si, že např. tištěný novinový text není vždy dokonalý. Může být drobně rozpitý, neostrý nebo nepatrně "poškozený". Čím kvalitnější databáze je, tím méně korektury bude potřeba. Velmi dokonalé databáze dokáží rozlišit i rukou psaný text, který má mnohdy k dokonalosti opravdu daleko.

Databáze by měla obsahovat nejméně 10 vzorků od každého písmene. Vytvořil jsem několik různých poloh písmene ve čtvercové síti a několik "nedokonalých podob" od každého znaku. Opět ale platí, že čím je databáze větší, tím přesnější výsledky získáme.


2.3.4 Transformace

Dalším krokem, stejně jako u prvního příkladu, je transformování obrazu na matici, tj. obrázek převést na číselné hodnoty a jeden obrázek po řádcích rozvinout jen na jeden řádek. Obrázek je tedy opět nutné převést na binární kód. Za bílé políčko dosadíme 0, za černé 1. Stejně jako u příkladu číslo 1. Jakmile je každý vzorek rozložen na řádek číslic, můžeme jej vložit jako vstupní informace do sítě.

2.3.5 Trénink



Obr. 17: Graf nenatřené databáze. Osa X představuje počet epoch a osa Y RMS.



Obr. 18: Graf natřené databáze. Osa X - počet epoch, osa Y - RMS.

Máme připraveno dvacet vzorků písmen, neboli 20 různých řádků. Nyní je zapotřebí databázi natrénovat tak, aby neuronová síť dokázala určit naše znaky s téměř stoprocentní úspěšností.

Po spuštění trénovacího procesu nastavíme pro jednu periodu trénování 1000 epoch.

Treninkový proces opakujeme dokud hodnota RMS (Error T) nestagne.

Při trénování naší databáze geometrických obrazců jsme celý proces opakovali sedmkrát. Z grafu na obrázku 18 je to na ose X patrné. Tato osa zobrazuje hodnotu, která vznikne vynásobením počtu epoch s počtem period v jedné epoše. Graf, který vznikne v poslední fázi tréninku nám dává jasně najevo, že je trénink úspěšně u konce. Čím více přiléhají asymptoty k osám, tím kvalitnější databázi jsme získali.

Vše nakonec ověříme procesem verifikace a predikce (1.3.3).

Vše dopadlo jak má a výstupy jsou přípustné, dosáhli jsme kýženého cíle a získali jsme plně funkční neuronovou síť s kvalitní databází pro rozlišování dvou písmen latinské abecedy.

2.4 Příklad III: Tachinidae

2.4.1 Úvod

V praktickém příkladu číslo 3 bych chtěl vysvětlit metodu rozpoznávání hmyzu pouze pomocí umělých neuronových sítí, bez aplikace Pattern Recognition. Tento postup dodnes využívá přírodovědecká fakulta Masarykovy univerzity v Brně (prof. RNDr. Josef Havel, DrSc. a prof. RNDr. Jaromír Vaňhara CSc.) pro klasifikaci druhů much a zaznamenali s touto prací velké úspěchy. Důvod, proč tento příklad uvádím je, abych ukázal jiný způsob určování druhů pomocí umělých neuronových sítí.

2.4.2 Materiál (data) a software

Byly vybrány čtyři druhy z rodiny *Tachinidae* (*Diptera*), jmenovitě tedy *Tachina* Meigen, *T. Fera*, *T. Magnicornis* a *T. Nupta*. Materiál zahrnoval dohromady 113 jedinců (58 sameček a 55 samiček), kteří byly nejdříve identifikováni J. Vaňharou pomocí klíče Tschorsnig & Herting.

Vysušení jedinci (nabodnuti na špendlík) byli vyfotografováni stereomikroskopem OLYMPUS SZX 12 s připojeným digitálním fotoaparátem Camedia C-5050. Digitalizovaný snímek byl poté opatřený měřítkem (v μm) pomocí analýzy fotografie softwarem M.I.S QuickPhoto Micro Olympus.

Výpočet ANN byl proveden v TRAJAN Neural Network Simulator, verze 3.0 D. (TRAJAN Software Ltd 1996–1998, UK). Některé výpočty (souhrnná statistika, test pro závislé vzorky, skupinová analýza) byly provedeny v STATISTICA V.7 (StatSoft, Inc., USA). Všechny operace proběhly na standardním PC s operačním systémem Microsoft Windows XP Professional.


2.4.3 Postup

Základním rozdílem mezi tímto a předchozím příkladem je, že zde neaplikujeme metodu Pattern Recognition. V praxi to znamená, že jednotlivé pixely snímku nepřevádíme na binární kód (tedy 1,0 ; černá, bílá), ale jako data nám slouží různé vzdálenosti na žilnatině (Obr. 19). Na křídle určí entomolog několik referenčních bodů, jejichž spojením získáme soubor několika vzdáleností (v našem případě 16). Vzdálenosti byly měřeny ručním umístěním bodu pomocí počítačové myši v programu QuickPhoto, který poté automaticky vypočítal požadovanou vzdálenost.

Při pohledu na žilnatinu mušičího křídla můžeme vidět, že pro každý druh je žilnatina typická, charakteristická a jedinečná podobně jako otisk prstu, ovšem v rámci druhu. Vzdálenosti jednotlivých referenčních bodů na žilnatině křídla mohou být v rámci druhu rozdílných velikostí (podobně jako máme malé a velké lidi, ale stále jsou to lidé), ale jejich poměr je vždy zachován. Naměřené hodnoty různých délek pro každý druh tvoří databázi, pomocí které poté určujeme jednotlivé druhy.

2.4.4 Měření vzdáleností na křídle

- 1 - (cs₁) - délka části sekce cs₁ žilky C;
- 2 - (cs₂) - délka žilky sekce cs₂;
- 3 - (cs₃) - délka žilky sekce cs₃;
- 4 - (cs₄) - délka žilky sekce cs₄;
- 5 - (cs₅) - délka žilky sekce cs₅;
- 6 - (R₁) - délka oblouku R₁;
- 7 - (R₂₊₃) - délka oblouku R₂₊₃;
- 8 - (R₄₊₅) - délka oblouku R₄₊₅;
- 9 - (M část 1.) - délka základní části střední žilky, tzn. mezi bodem spoje bm-cu a obloukem M;
- 10 - (M část 2.) - délka úhlové pozice žilky, tzn. střední žilka M od které je ohnuta ke konci;
- 11 - (CuA₁ část 1.) - délka přední větve CuA₁ loketní žilky, je to část mezi bm-cu a dm-cu;
- 12 - (dm-cu) - délka střední loketní křížové žilky dm-cu;
- 13 - (r-m) - délka střední obloukové křížové žilky r-m;
- 14 - (bm-cu) - délka základní střední loketní křížové žilky bm-cu;
- 15 - (2nd) - šířka tykadlové části 2, ve které je nejširší;
- 16 - (3rd) - šířka tykadlové části 3, ve které je nejširší;
- 17 - (pohlaví; M, F) - sameček, samička.



Obr. 19: Křídlo s jednotlivými vzdálenostmi na žilnatině a část mušního tykadla.

Soubor těchto hodnot (tedy 14 hodnot na křídle, 2 na tykadle a 1 hodnota určující pohlaví) tvoří jednu vstupní informaci. Dostaneme tedy tabulku o 113 řádcích, přičemž 113 označuje počet jedinců v databázi.

VSTUPNÍ INFORMACE																	VÝSTUP
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	druh
2364.8	1876.9	2541.2	674.1	112.9	4352.1	5814.1	6487.8	5302.1	2018.1	3206.8	1607.5	186	196.6	394	588.8	M	<i>T. fera</i>
2308.6	1675.9	2146.5	768.8	188	4217.8	5296.3	6102.5	4556.4	2225.3	3165	1237	215	196.6	410.3	528.3	F	<i>T. magnicornis</i>
2414.6	1734.3	2395.9	751.8	204.3	4464.6	5875.8	6663.5	5110.9	2417.7	3369.5	1430.2	259.9	290.2	470.1	742.7	M	<i>T. nupta</i>

3

APLIKACE NA DIGITÁLNÍ FOTOGRAFIE KŘÍDEL

- Použitá data (databáze)
- Úprava fotografie do optimálního stavu
- Transformace digitálních dat fotografie
- Architektura umělé neuronové sítě
- Trénink
- Výsledky

3.1 Úvod

Tato kapitola je stěžejní částí mého projektu. Pojednává o využití metody Pattern Recognition v praxi a její aplikaci na dva blízké druhy much *Tachina (Servillia) ursina* (Meigen, 1824) a *Tachina (Tachina) grossa* (Linnaeus, 1758). V podstatě se jedná o složitější verzi praktického příkladu číslo 1 či 2. Rozdíl je pouze ve velikosti vstupních informací.

Kapitola podrobně popisuje jak a proč musí být fotografie upravena před jejím použitím a podrobný popis postupu úpravy snímku do optimálního stavu. Popisuje rovněž jednotlivé kroky redukce. Fotografie je dále podle určitého pravidla transformována na matici.

3.2 Použitá data (databáze) + software & hardware

Data, se kterými jsem pracoval, jsou zredukováno (str.33-34) fotografie muších křídel. Konkrétně se jedná o levá křídla samiček rodu *Tachina (Servillia) ursina* (Meigen, 1824) a *Tachina (Tachina) grossa* (Linnaeus, 1758).

Fotografie byly pořízeny stereomikroskopem OLYMPUS SZX 12 s připojeným digitálním fotoaparátem Camedia C-5050. Překrývání mikrografických vrstev bylo realizováno softwarem Helicon-Focus a následně byly fotografie upraveny v programu Paint Shop Pro 8.

Úprava digitální fotografie do optimálního stavu (3.3) byla provedena programem Adobe Photoshop CS3 na 24-inch iMac, 2.8 Ghz Intel Core 2 Duo a operačním systémem Mac OS X Leopard 10.5.6.

Výpočet ANN proběhl na standartním PC Acer 2.4 Ghz s operačním systémem Windows Vista Ultimate.


3.3 Úprava fotografie do optimálního vzhledu

3.3.1 Úvod

Než vůbec začneme se samotným rozpoznáváním fotografií, je zapotřebí uvést ji do optimálního stavu, tedy stavu, kdy maximálně vyhovuje pro aplikaci metody Pattern Recognition. Když fotografii pořizujeme, získáme velice kvalitní, detailní, barevný snímek (Obr. 20). Ať je to sebezvláštější, my pro naše účely potřebujeme pravý opak. Černobílý, zredukováno obrázek (Obr. 21).



Obr. 20: Původní podoba fotografie bez jakéhokoliv úpravy.



Obr. 21: Konečný stav fotografie po její úpravě (viz níže).

Proč je ale vlastně nutné fotografii takto upravovat? Vše se odvíjí od příkladu č. 1. Princip zpracování dat bude úplně stejný, protože je důležité si uvědomit, že nezáleží natom, jestli určujeme čtverec, křídlo, lidský obličej nebo cokoli jiného. Vždy jde o stejný princip, který se liší pouze složitostí.

Pro naše účely využíváme ze snímku pouze žilnatinu křídla. Proto je vše ostatní rušivým a nežádoucím elementem. Např. tělo jedince, pozadí, odlesky, blanitá výplň křídla, různá poškození, vady, barevnost snímko atd. Toto vše je nutné odstranit a z fotografie "vyzdvihnout" pouze žilnatinu.

Pokud se vrátíme k praktickému příkladu číslo 1 a podíváme se na použitou čtvercovou síť, zjistíme, že její rozlišení činilo $5 \times 5 = 25$ px. Skutečná digitální fotografie křídla, se kterou budeme pracovat, má rozlišení 2560×1920 . To je téměř 5 milionů pixelů. Dosazování takovýchto hodnot by nebylo v lidských silách a především by to bylo úplně zbytečné. Fotografii je nutné opět transformovat na číselné hodnoty. Postup bude ale téměř stejný jako u geometrických obrazců. Rozdílem bude pouze rozlišení sítě (počet pixelů). Proto musíme nutně provést výše zmiňovanou redukci⁵ fotografie, abychom získali přípustný počet pixelů. Teprve poté můžeme zadávat hodnoty z fotografie do programu.

3.3.2 Postup úpravy fotografie

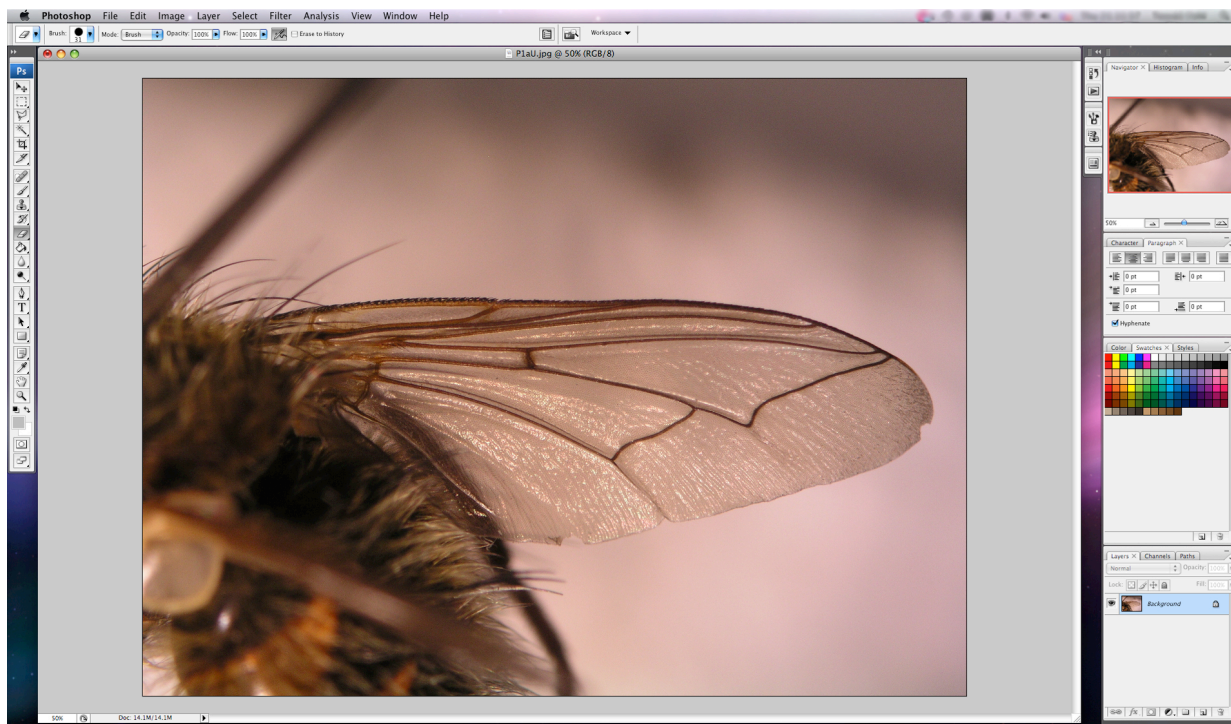
Úprava fotografií probíhá v několika základních krocích. Každý z nich byl proveden v programu Adobe Photoshop CS3 a každý krok bude podrobně popsán a znázorněn na doprovodných screenshotech. Číselné hodnoty se mohou u jednotlivých fotografií drobně lišit.

Celý proces se skládá z pěti různých kroků. Úprava fotografie zabere cca 1 minutu. Je to velmi krátký čas a databáze je tedy připravena za velmi krátký čas a následná determinace vzorků je rovněž časově nenáročná.

⁵ **Redukce fotografie** = komprimace je proces, při kterém se velmi kvalitní digitální fotografie zredukuje na méně kvalitní a to pomocí redukce (snížení) počtu pixelů fotografie. Toho dosáhneme prostým zmenšením rozměrů stran fotografie při jejich zachovaném poměru.

3.3.2.1 Původní fotografie


Na obrázku č. 22 můžeme vidět původní podobu fotografie křídla otevřenou v programu Adobe Photoshop CS3. Kvalitní barevný digitální snímek, velmi detailní a přesný, ovšem pro naše účely naprosto nevyhovující. Uvádím zde tento screenshot, abychom se rychle seznámili se základním uživatelským rozhraním. Na levé straně je umístěn panel nástroju, na pravé poté rozšířené nastavení jednotlivých situací a funkcí.



Obr. 22: Původní podoba fotografie bez jakékoliv úpravy otevřená v programu Adobe Photoshop CS3, ve kterém bude celá úprava probíhat.

3.3.2.2 Krok č.1 - Oříznutí


Jak je vidět na původních fotografiích, objevuje se na nich i tělo jedince a okolní pozadí, někdy na snímku "zavazí" např. noha či tykadlo, případně nečistota na podkladu. To vše je na obrázku naprosto nežádoucí a je potřeba - zvláště tělo jedince - odstranit. Jako odlišovací znaky, resp. naše databáze slouží pouze musí křídlo a jeho žilnatina. To je to jediné co potřebujeme, to jediné co zohledňujeme a určujeme. Proto je nutné fotografii oříznout tak, abychom získali pouze čisté křídlo. Jak můžeme na fotografii vidět, kořen křídla (jeho začátek, tedy nejbližší těla) je poměrně nejasný a z části zakrytý tělem mouchy. Bude tedy vhodné tuto část odstranit, resp. nezahrnout ji do ořezu. Na křídle jsem tedy určil bod, ze kterého budou všechny ořezy začínat. Tento bod se nachází v místě, kde se sbíhají žilky, v první třetině křídla zleva (Obr. 23).



Obr. 23: Výběr pro ideální ořez vymezený referenčními body.

3.3.2.3 Krok č.2 - Převedení na stupně šedi

Velmi jednoduchý, o to ale podstatnější krok. Barevná fotografie, která obsahuje 16 700 000 barev je zcela zbytečná, jelikož pro naši potřebu nám stačí pouze 256 hodnot (podobě jako 2 hodnoty u binárního kódu) stejně jakou u prvních dvou praktických příkladů. Prozatím převedeme snímek na 256 stupňů šedi. *Image => Adjustments => Black & White* (Obr. 24).

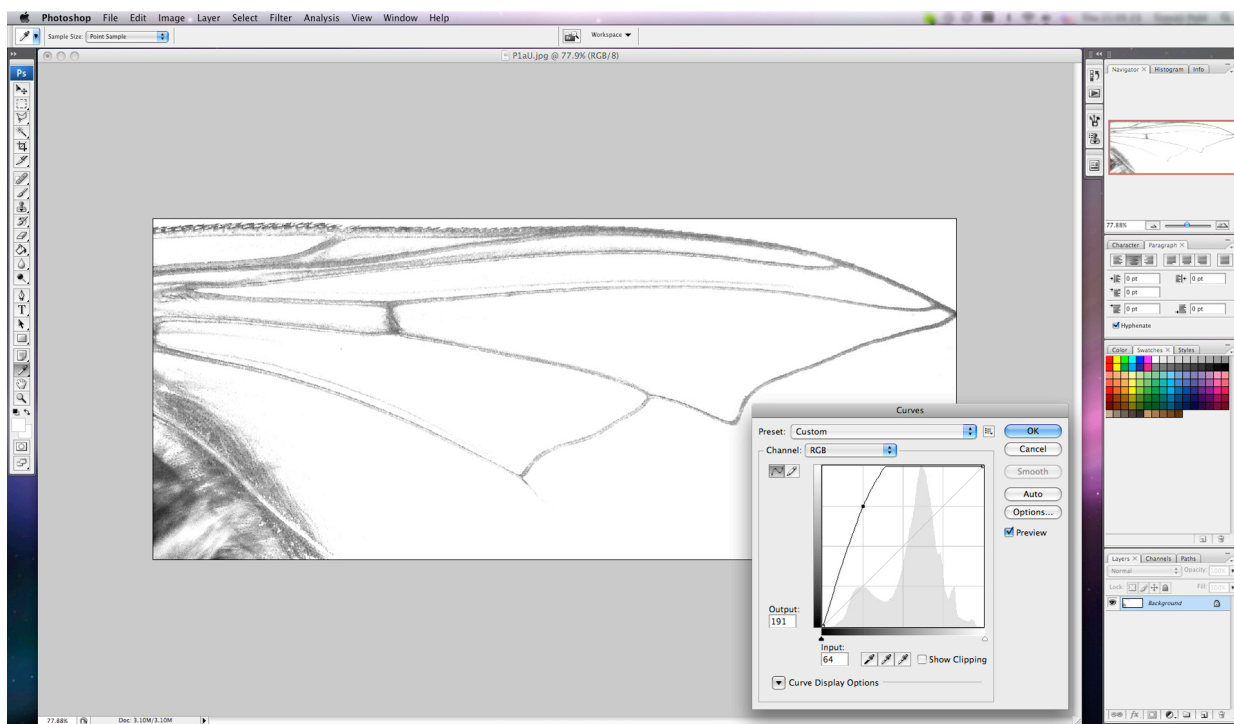


Obr. 24: Fotografie, která byla převedena na 256 stupňů šedi.

3.3.2.4 Krok č.3 - Aplikace efektu Curves

Podstatou tohoto kroku je zvýraznit žilnatinu křídla a ostatní části fotografie "ztlumit". Toto je nezbytné, jelikož jako charakteristický a určovací znak pro determinaci používáme žilnatinu. Proto nás kromě ní v podstatě nic jiného nezajímá. K dosažení tohoto efektu nám poslouží funkce Curves, kterou Photoshop nabízí. *Image => Adjustments => Curves*.

Zobrazí se nám malé okno (Obr. 25), ve kterém můžeme vidět histogram⁶ snímku a křivku ležící na histogramu. Posunutím a upravováním křivky můžeme postupně dosáhnout požadovaného efektu. Program nám opět nabízí několik předem přednastavených možností. Po opětovném vyzkoušení všech těchto možností, se ani jedna přednastavená volba nejeví jako vhodná a proto vše nastavíme ručně. Křivku posunujeme do optimální polohy na histogramu dokud požadovaného efektu nedosáhneme (Obr. 25).

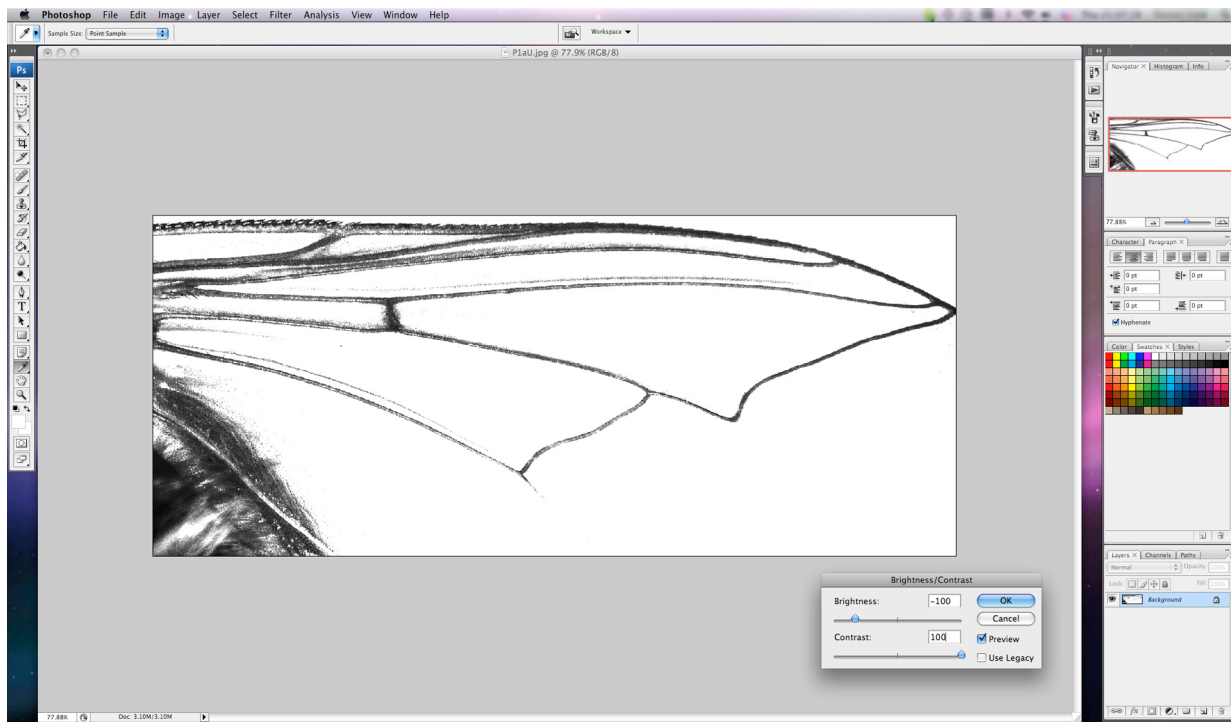


Obr. 25: Fotografie po aplikaci Curves efektu, který umožní vymazat pozadí a zvýraznit žilnatinu.

3.3.2.5 Krok č.4 - Nastavení jasu a kontrastu

Při úspěšném provedení kroku 2 jsme zvýraznili žilnatinu a pozadí utlumili. Pokud si ale žilnatinu prohlédneme detailněji, zjistíme, že je mírně zašedlá a světlá. Proto ji musíme pomocí nastavení jasu (angl. Brightness) a kontrastu (angl. Contrast) ještě více zvýraznit. Velmi jednoduchým nastavením požadovaných hodnot jasu a kontrastu tohoto efektu dosáhneme. *Image => Adjustments => Brightness/Contrast*. Jako nejvhodnější se jeví brightness: -100 a contrast: 100 (Obr. 26). Nyní vidíme, že je žilnatina o hodně tmavší, tudíž výraznější.

⁶ **Barevný histogram** je reprezentací rozložení barev v obraze. Používá se v počítačové grafice a digitální fotografii. Vyjadřuje poměrné zastoupení počtu pixelů každého z daných barevných rozsahů v buď dvourozměrném (2D) nebo třírozměrném (3D) barevném modelu.




Obr. 26: Snímek po zvýšení kontrastu na maximum a snížení jasu, což způsobí zvýraznění žilnatiny.


3.3.2.6 Krok č.5 - Ideální redukce fotografie

Velmi nezbytný krok, který je nutné provést, abychom vůbec technicky celý proces determinace snímku byli schopni provést.


Jak jsem již zmínil v úvodu (3.3.1), je nutné zredukovat počet pixelů na nejmenší možné množství. Pokud provedeme několik jednoduchých výpočtů, okamžitě uvidíme proč. Původní digitální fotografie má rozlišení 2560x1920. To činí neuvěřitelných 4 915 200 px. Pokud bychom takovou fotografii vložili do databáze, jedna vstupní informace by byla tvořena téměř pěti miliony čísly. Tyto dva poměry můžeme vidět na grafu v obrázku 27. To si nemůžeme dovolit hned z několika důvodů. Zaprvé nám program TRAJAN neumožňuje vkládat tak "dlouhou" informaci a druhý důvod je ten, že výpočet s tak obrovskými vstupními informacemi by trval několik dní. Fotografii je tedy nutné zredukovat na přijatelný počet pixelů. Je důležité si uvědomit, že při redukci dochází k velkému znekválení fotografie. Existuje určitá mez zhoršení kvality, kterou ještě sneseme, překročíme-li ji ovšem, dojde k deformaci žilnatiny na snímku a tedy i nepoužitelnosti vzorku. Z tohoto důvodu jsem provedl 6 stupňů redukce a našel co nejvyšší možnou redukci, aniž by došlo k deformaci žilnatiny.



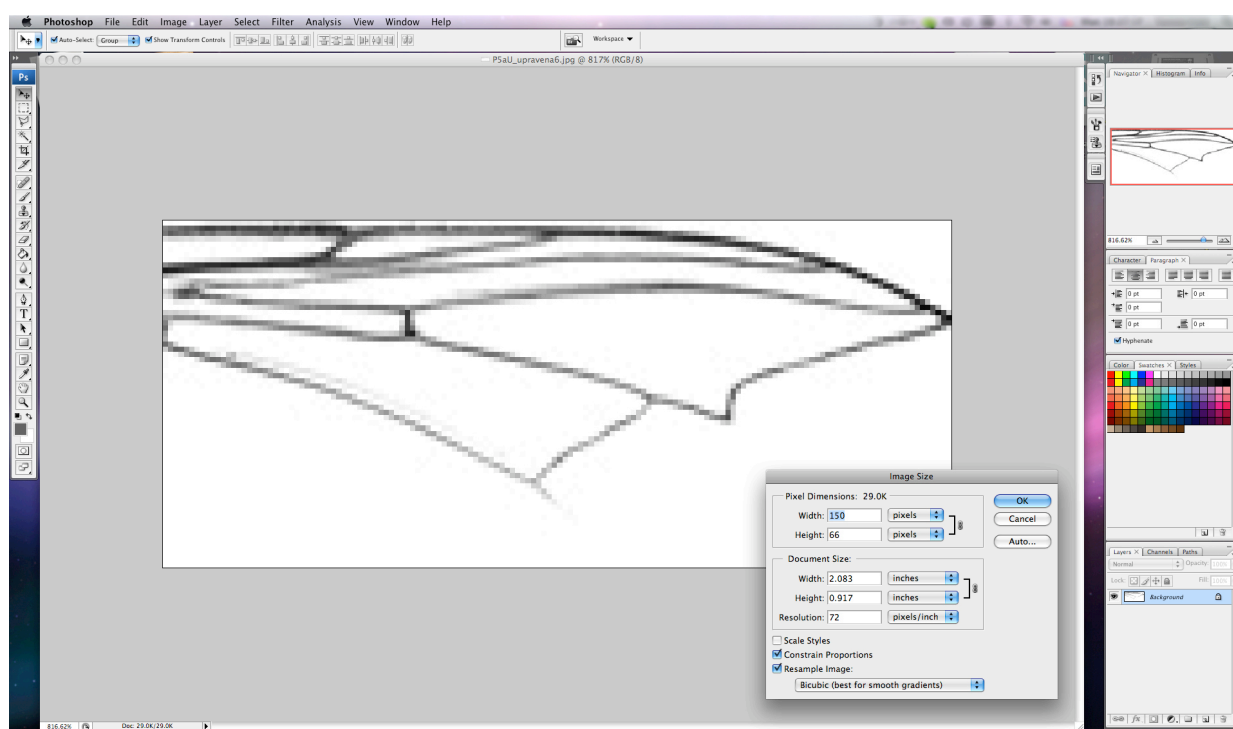
Obr. 27: Poměr původního snímku a zredukové fotografie. Z grafu plyne, jak důležité je křídlo redukovat.



Obr. 28: Upravená fotografie mušního křídla, která nebyla podrobena redukcí. Její rozměry jsou tedy 1770x774 pixelů, výsledný počet pixelů je tedy 1 369 980 px.



Obr. 29: Upravená fotografie mušního křídla, která byla redukována na 150x66 pixelů, výsledný počet pixelů je tedy 9 990 px.



Obr. 30: Fotografie podrobená redukcí o výsledných rozměrech 150x66 pixelů.

Jako nejvhodnější se zdá redukce přibližně okolo 150x66 pixelů. Redukce větší je již za hranicí použitelnosti a obrázek je nepoužitelný. Čím menší redukce je, tím lépe, jsme ovšem limitováni omezenou velikostí řádku.

3.4 Transformace digitálních dat fotografie

3.4.1 Princip

Jakmile máme fotografii optimálně upravenou, můžeme začít s transformací snímku na matici. Pokud se opět vrátíme k praktickému příkladu č. 1 (strana 18), můžeme se jím inspirovat, protože princip a postup je absolutně stejný, rozdílem je pouze větší počet pixelů. A právě tento výrazně vyšší počet pixelů je nevýhodou oproti prvnímu praktickému příkladu. V geometrických obrázcích jsem použil síť o rozlišení 10x10. Výsledkem byla tedy síť o rozlišení 100 px, resp. jednoduchá fotografie o rozlišení 100 px. Mnou zreduková fotografie o rozměrech 150x66 má rozlišení 9900 px. Je na první pohled jasné, že nemůžeme fotografii převést na číselné hodnoty pouze z hlavy, jako jsme to udělali u čtverců a obdélníků. Teoreticky by to možné bylo, pokud bychom měli fotografii vytisknutou tak velkou, že by bylo vidět jednotlivé pixely, ale jednalo by se o naprosto zbytečně zdlouhavý a složitý proces. Abychom tedy zredukovanou fotografii převedli na soubor číselných hodnot, napsali jsme jednoduchý program, který umožňuje export *JPEG*⁷ do textového dokumentu, přičemž každý 1 pixel nahradí skupinou tří čísel. Tří proto, že každé číslo představuje hodnotu jednoho barevného kanálu *RGB*⁸. Např. hodnoty 189^R 200^G 195^B. Každý pixel je tedy nahrazen třemi číselnými hodnotami. Je to tedy stejná situace, jako u prvních dvou praktických příkladů, rozdílem je pouze to, že pixel není nahrazen jednou číslicí 1 či 0, ale kombinací tří hodnot RGB kanálů.

3.4.2 Program pro transformaci fotografie

Program byl napsán v jazyce C++ pomocí OpenCV. OpenCV (Open Source Computer Vision) je knihovna programovacích funkcí zaměřená především na real time počítačové vidění. OpenCV velmi úzce souvisí s Pattern Recognition. Vypovídá o tom i využití OCV. Příkladem aplikace knihovny jsou identifikace objektů, segmentace a rozpoznávání obličejů, rozpoznávání gest atd.

Jde o jednoduchou utilitu, která umožňuje exportovat většiny formátů pro obrázky do textového souboru (v našem případě je fotografie ve formátu .jpg a exportujeme do .txt). Program jednoduše po zadání příkazu do příkazového řádku vyexportuje naši fotografii do textového souboru s názvem, který si určíme (zpravidla stejný název jako obrázek) a tento soubor uloží do složky, ve které se nachází i exportovaná fotografie.

7 **JPEG** - (vyslovováno originálně džipejg, ale užívá se též počeštěné výslovnosti jépeg nebo jpeg) je standardní metoda ztrátové komprese používané pro ukládání počítačových obrázků ve fotorealistické kvalitě. Formát souboru, který tuto kompresi používá, se také běžně nazývá JPEG. Nejrozšířenější příponou tohoto formátu je .jpg, .jpeg, .jfif, .jpe, nebo tato jména psána velkými písmeny.

8 **RGB** - Barevný model RGB neboli červená-zelená-modrá je aditivní způsob míchání barev používaný ve všech monitorech a projektorech (jde o míchání vyzařovaného světla), tudíž nepotřebuje vnější světlo (monitor zobrazuje i v naprosté tmě) na rozdíl např. od CMYK modelu.

```

#include <cv.h>
#include <string.h>
#include <highgui.h>
#include <stdlib.h>
#include <stdio.h>
#include <iostream>

int main(int argc, char *argv[]){
    IplImage* img = 0;
    int height,width,step,channels;
    uchar *data;
    int i,j,k;

    if (argc != 2) return -1;
    img=cvLoadImage(argv[1]);
    if(!img){
        printf("Could not load image file: %s\n",argv[1]);
        exit(0);
    }

    height    = img->height;
    width     = img->width;
    step      = img->widthStep;
    channels   = img->nChannels;
    data      = (uchar *)img->imageData;

    for(i=0;i<height;i++){
        for(j=0;j<width;j++){
            for(k=0;k<channels;k++){
                std::cout << (int)data[i*step+j*channels+k] << " ";
            }
        }
        std::cout << "\n";
    }
}

```

3.4.3 Postup

Pokud chceme tedy fotografii převést na číselné hodnoty, stačí pouze v příkazovém řádku zadat jméno souboru, který představuje náš program (v našem případě main.exe), napsat jméno jpg souboru pro převod a název souboru po exportu. Zápis tedy bude vypadat takto:

```
main.exe P9aU_R1.jpg > P9aU_R1.txt
```

```

C:\Windows\system32\cmd.exe
25.10.2008 13:37 <DIR> Searches
25.10.2008 13:37 <DIR> Videos
Souborů: 0, Bajtů: 0
Adresářů: 13, Volných bajtů: 21 408 165 888

C:\Users\...>cd Desktop
C:\Users\... \Desktop>cd ANN
C:\Users\... \Desktop\ANN>dir
Svazek v jednotce C nemá žádnou jmenovku.
Sériové číslo svazku je B417-D456.


Úypis adresáře C:\Users\... \Desktop\ANN
06.02.2009 17:52 <DIR> -
06.02.2009 17:52 <DIR> ..
25.01.2009 21:14 747 main.cpp
26.01.2009 18:52 37 376 main.exe
04.02.2009 20:59 49 758 P9aU_R1.jpg
06.02.2009 17:52 0 P9aU_R1.txt
Souborů: 4, Bajtů: 87 881
Adresářů: 2, Volných bajtů: 21 408 165 888

C:\Users\... \Desktop\ANN>main.exe P9aU_R1.jpg > P9aU_R1.txt

```

Obr. 31: Screenshot příkazového řádku po zadání příkazu pro export jpg do txt pomocí našeho programu.

Po provedení tohoto úkonu vyexportuje program číselné hodnoty do *.txt* souboru. Nyní stačí tabulku čísel pouze rozvést do jednoho řádku a tím jsme získali z digitální fotografie jednu vstupní informaci, kterou můžeme vložit do umělé neuronové sítě.



Obr. 32: Screenshot textového souboru v poznámkovém bloku. Každá tři čísla reprezentují jeden pixel.

4

ZÁVĚRY A SHRNUTÍ

- Výhody identifikace hmyzu pomocí ANN a PR
- Shrnutí
- Epilog

4.1 Výhody identifikace hmyzu pomocí ANN a PR

Proč bychom vlastně měli přikládat klasifikaci hmyzu pomocí ANN a Pattern Recognition takovou váhu? V čem je tato metoda jiná oproti těm co fungují dnes? A proč vůbec vyvíjet metodu novou, když tu máme ty staré a funkční? Odpověď je jednoduchá. Všechno jde lépe a snadněji.

4.1.1 Výhody oproti práci entomologa

Určování hmyzu je možné hned několika způsoby. Ten první je způsob nejpůvodnější a dodnes nejpoužívanější a to identifikace jedinců a jejich příslušnosti podle pozorování základních charakteristických znaků. Pokud jde o jedince blízkých druhů s velmi malými rozdíly, entomolog ho zkoumá celé hodiny, dny, někdy dokonce i týdny a podle speciálního entomologického klíče (velká kniha) jedince určí. Způsob jistě velmi dobrý, s velkou úspěšností, ovšem plný nevýhod. Zaprvé je nutné být entomologem, který tento obor studuje desítky let. Zadruhé je tato cesta velmi zdlouhavá a vyžaduje znalost čtení v klíčích a velkou trpělivost. Smyslem mé práce je navrhnout způsob, jak tento dlouhý a komplikovaný proces nahradit jednoduchou metodou, která je schopna po vytvoření vhodné databáze určit jedince během několika sekund.

4.1.2 Výhody oproti molekulárnímu rozboru

Druhým způsobem, jak bezpečně daný druh určit, je použít molekulární rozbor vzorku. Jedinec je podroben chemickému a molekulárnímu rozboru, který na základě porovnání s databází určí k jakému druhu vzorek patří. Tato metoda je sice rychlejší než metoda předešlá, ale její největší nevýhodou je nevyhnutelné zničení vzorku. To si ve většině případů nemůžeme v žádném případě dovolit, jelikož se často jedná o vzorky z osobních sbírek entomologů, či dokonce velmi vzácné muzejní kousky. To nepřipouští jakékoliv poničení vzorků, což ve většině případů vylučuje použití této metody. Zde opět přichází na řadu metoda ANN, popřípadě Pattern Recognition, která během chvilky umožní identifikaci a vzorku se u toho nemusí nikdo ani dotknout, pouze vyfotografovat např. křídlo.

4.2 Shrnutí

Na úplný závěr celé mé práce bych rád shrnul čo jsem v projektu dokázal a čeho jsem dosáhl. V první fázi práce byla úspěšně zvládnuta technika aplikace umělých neuronových sítí pro rozpoznávání vzoru. To znamená vyřešení otázky, jak transformovat fotografie či malé obrázky do vstupních informací, tedy transformace jednoho snímku na jeden řádek číselných hodnot, který je poté vložen do sítě coby jedna vstupní informace. Toto byl zásadní krok vpřed, jelikož bez něho bychom nebyli schopni dále pokračovat.

V okamžiku, kdy jsem byl schopen vložit fotografii jako vstup, přešel jsem ke zkoušce celého systému v praxi. Bylo použito několika základních příkladů pro ověření a potvrzení funkčnosti umělých neuronových sítí v kombinaci s rozpoznáváním vzoru a u třetího příkladu klasifikace

druhů pouze pomocí umělých neuronových sítí. U všech příkladů byla úspěšně vytvořena dostačující databáze s již transformovanými obrázky, byla úspěšně nalezena optimální architektonická struktura sítí pomocí RMS. Na této architektuře byla databáze natrénována a konec tréninkového procesu byl ověřen vložím předem nezahrnuté vstupní informace. Výsledkem celého tohoto procesu byla úspěšná determinace (určení) všech vzorků (objektů na snímku).

V poslední fázi byly započaty kroky k úspěšné determinaci fotografií hmyzu, v našem případě klasifikace pomocí fotografií muších křídel. Byla úspěšně vyřešena otázka úpravy fotografie do optimálního stavu a vyřešeny základní principi redukce. Snímek byl následně úspěšně transformován na číselné hodnoty pomocí vhodného programu. K dosažení stoprocentní determinace druhů na fotografiích chybí již jen malý krůček a v práci se nadále pokračuje.

Epilog

Závěrem bych chtěl opět poděkovat všem zainteresovaným osobám, kteří mi v práci pomohli a byli mi oporou. Jmenovitě především prof. RNDr. Josefu Havlovi, DrSc. a prof. RNDr. Jaromíru Vaňharovi CSc.

Považuji za důležité sdělit, že si práci prodlužuji i na příští školní rok. Tento rok šlo tedy "pouze" o vytvoření jakési metody, která by taxonomickou identifikaci pomocí Pattern Recognition a umělých neuronových sítí umožnila. To se nám povedlo a dalším mým krokem tedy bude dotáhnout tuto práci do zdárného konce, umožnit tedy plně funkční využívání této metody v praxi.

Od prvního dne, kdy jsem začal na své středoškolské odborné činnosti pracovat, plně jsem jí propadl a na následující půlrok pro mne byla alfou a omegou. To je to, o co v soutěžích jako je SOČ jde. Ne o výsledek či úspěch, ale o nadšení a obrovský zájem o téma, které si zvolíme.

Tomáš Pohl

Seznam použité literatury a internetu

BYERS, John A.; Analysis of Insect and Plant Colors in Digital Images Using Java Software on the Internet; Western Cotton Research Laboratory, USDADARS, 4135 East Broadway Road, Phoenix, AZ 85040

CHON, Tae-Soo; PARK, Young-Seuk; PARK, Ki Yun; CHOI, Se-Young; KIM, Tai Kyong; CHO, Eung Chun; Implementation of computational methods to pattern recognition of movement behavior of *Blattella germanica* (Blattaria: Blattellidae) treated with Ca²⁺ signal inducing chemical; *Appl. Entomol. Zool.* 39 (1): 79-96 (2004)

CHOVANEC, Lukáš; Hypertextová příručka k předmětu umělá inteligence; Dostupné z URL: <[http://ui.fpf.slu.cz/diplomky/umela_inteligence/UI.html](http://ui.fpf.slu.cz/diplomky/umela_intelligence/UI.html)>

GASTON, Kevin J.; O'NEILL, Mark A.; Automated species identification: why not?; *Phil. Trans. R. Soc. Lond. B* (2004) 359, 655-667; DOI 10.1098/rstb.2003.1442

KROGH, Anders; What are artificial neural networks?; *Nature biotechnology*, volume 26, number 2, February 2008

MACLEOD, Norman; Automated Taxon Identification in Systematics Theory, Approaches and Applications; Natural History Museum, London, UK

MALMGREN, Helge; Artificial Neural Networks in Medicine and Biology; A philosophical introduction; Opening lecture at the ANNIMAB-1 conference, Göteborg, May 13-16, 2000; Department of Philosophy, Göteborg University

VANĚHARA, Jaromír; MURÁRIKOVÁ, Natália; MALENOVSKÝ, Igor; HAVEL, Josef. Artificial neural networks for fly identification: A case study from the genera *Tachina* and *Ectophasia* (Diptera, Tachinidae); *Biologia*, Bratislava, 62/4: 462—469, 2007

WEEKS, P.J.D; GAULD, I.D.; GASTON, Kevin.J.; O'NEILL, Mark.A.; Automating the identification of insects: a new solution to an old problem; *Bulletin of Entomological Research* (1997) 87, 203-211

<http://www.learnartificialneuralnetworks.com/>

<http://www.opencv.willowgarage.com/>

<http://www.bioprotection.org.nz/>

<http://www.wikipedia.org>