

VYUŽITÍ KOHONENOVY MAPY GENERALIZAČNÍHO GRADIENTU KLASIFIKAČNÍ UMĚLÉ NEURONOVÉ SÍTĚ JAKO UŽIVATELSKY VSTŘÍČNÉHO NÁSTROJE VÝBĚRU, UMISŤOVÁNÍ A ROZVOJE ZAMĚSTNANCŮ

LUDEK STEHLÍK

Předmětem článku je návrh uživatelsky vstřícného a snadno aktualizovatelného nástroje, který personalistům může usnadnit jejich každodenní rozhodování v otázkách výběru, umisťování a rozvoje zaměstnanců. Navrhovaný nástroj má podobu kombinace tří prvků: (a) benchmarkové studie ideálního profilu kandidáta na určitou pracovní pozici, (b) dopředné třívrstevné umělé neuronové sítě použité ke zpracování dat z benchmarkové studie a ke klasifikaci zaměstnanců a uchazečů do dvou různých výkonnostních skupin a (c) Kohonenovy samoorganizující mapy umožňující vizualizaci generalizačního gradientu klasifikační umělé neuronové sítě. Uživatelské rozhraní navrhovaného nástroje má podobu sady map se stejným topografickým uspořádáním a odlišným výškovým profilem podle zobrazené proměnné. Z těchto map personalista dokáže velice snadno vyčíst řadu důležitých a užitečných informací, které může bezprostředně využít při svém rozhodování v řadě personálních otázek.

Klíčová slova: lidské zdroje, benchmark, umělé neuronové sítě, Kohonenovy samoorganizující mapy, generalizační gradient, vizualizace vícerozměrných dat

Úvod

Dnes je již všeobecně uznávanou pravdou, že tím nejcennějším, co firma má, jsou její zaměstnanci. Bez kvalitních lidských zdrojů je úspěch v dnešním světě tvrdé konkurence nemyslitelný. Kvalitní zaměstnanci představují onen příslovecný jazýček na vahách, který rozhoduje o tom, kdo v konkurenčním boji obstojí a kdo nikoli. Není proto divu, že firmy vynakládají nemalé finanční prostředky do procesu výběru a rozvoje svých zaměstnanců. Vědí totiž, že se jim jejich investice nakonec mnohonásobně vrátí – v podobě ušetřených nákladů na vyškolení neperspektivních zaměstnanců, nižší fluktuace, motivovanějších a výkonnějších zaměstnanců a nakonec i lepších ekonomických výsledků celé firmy. Některé z klíčových otázek pro personalistu proto zní „*Jak vybrat toho správného člověka na danou pozici?*“, „*Co udělat pro to, aby tento zaměstnanec byl na své pozici úspěšný?*“ či „*Na jaké konkrétní pozici by byl tento člověk s nejvyšší pravděpodobností úspěšný?*“. Tento článek se zabývá možností kombinace dvou různých typů umělé neuronové sítě a jejich společného využití jako uživatelsky vstřícného nástroje, který by personalistům umožnil snadno a rychle, ale hlavně kvalifikovaně odpovídat sobě, svým kolegům a nadřízeným na výše naznačený typ otázek.

Benchmarková studie ideálního profilu kandidáta

Při výběru nového zaměstnance na určitou pracovní pozici se většinou vychází z tzv. kompetenčního modelu – popisu ideálního profilu pracovníka, resp. požadavků, které by měl kandidát na dané pracovní místo splňovat, aby ho mohl úspěšně zastávat. Pověstným úzkým hrdlem, kde se především rozhoduje o efektivitě celého výběrového procesu, je kvalita výběrových kritérií kompetenčního modelu – ta by měla umožnit od sebe odlišit budoucí úspěšné a neúspěšné zaměstnance, snížit pravděpodobnost chybného rozhodnutí a učinit z výběru něco více než jen snůšku dojmů, intuice a pokusů a omylů. Naneštěstí je formulování výběrových kritérií často zatíženo řadou více či méně systematických chyb, daných především skrytými předpoklady, vlastními zájmy, předsudky a obecně vždy nějak omezenou perspektivou toho, kdo kompetenční model sestavuje. Reálně tak hrozí, že se z formulování kompetenčního modelu stane svého druhu projektivní technika, která více vypovídá o osobě, která model sestavovala než o samotné pracovní pozici. Realita je navíc většinou tak složitá a lidská mysl a představivost tak omezená, že se jen málokdy podaří „od zeleného stolu“ postihnout všechny ty komplexní vztahy a souvislosti mezi různými proměnnými, které z člověka dělají ne/vhodného kandidáta na danou pozici.

Riziko podobného zkrácení a omezení kompetenčního modelu významně redukuje realizace benchmarkové studie pro danou pozici. Její podstatou je empirické zjištění těch vlastností, které nejlépe rozlišují úspěšné a neúspěšné zaměstnance na dané pozici. Postup při realizaci benchmarkové studie je takový, že se nejdříve podle jasně definovaných a měřitelných kritérií identifikuje minimálně 30 nejlepších a 30 nejhorších stávajících zaměstnanců na dané pozici a následně se zjišťuje, jaké charakteristiky mají zaměstnanci v rámci jedné výkonnostní skupiny společně, resp. kterými charakteristikami se mezi sebou dvě různé výkonnostní skupiny zaměstnanců liší. Taková zjištění jsou založena na tvrdých datech, a tak dávají jen minimální prostor subjektivním dojmům, intuici a dalším chybám vyplývajících z omezené perspektivy sestavovatele kompetenčního modelu (více viz text v příloze 1).

Statistická metoda diskriminační analýzy

Výraznou pomocí při sestavování kompetenčního modelu na základě takto získaných údajů je řada různých statistických nástrojů – od těch deskriptivních, umožňujících bez významné ztráty informací přehledné shrnutí většího množství dat, přes konfirmační, umožňující zjistit míru nenáhodnosti a statistické významnosti zjištěných rozdílů mezi dvěma výkonnostními skupinami zaměstnanců, až po ty explorační, umožňující hlubší vhled a porozumění shromážděným údajům a hlubší pochopení vztahů mezi sledovanými proměnnými.

Z hlediska hlavního účelu realizace benchmarkové studie je jedním z nejužitečnějších nástrojů statistická metoda diskriminační analýzy – ta umožňuje v souboru dvou či více výkonnostních skupin zaměstnanců nalézt taková kategorizační kritéria, která umožňují každého dalšího nového zaměstnance/kandidáta správně kategorizovat a zařadit do jedné z existujících výkonnostních skupin. Primárním výstupem takové diskriminační analýzy je matematický model, který maximálně vystihuje rozdíly mezi dvěma výkonnostními skupinami a který může být (po náležité implementaci, např. v rámci jednoduché

excelovské aplikace) personalistou přímo využíván jako detektor či rozpoznávač neúspěšných kandidátů na danou pracovní pozici, a to v jakékoli fázi přijímacího řízení, ať už v rámci úvodního screeningu velkého počtu kandidátů nebo při finálním rozhodování se mezi několika málo zbývajících uchazeči. Vedlejším (avšak často tím nejdůležitějším) produktem diskriminační analýzy je pak identifikace těch charakteristik, které jsou nejužitečnější a nejvýhodnější pro určení příslušnosti zaměstnance/kandidáta do jedné z výkonnostních skupin, a které tak mohou být využity k nastavení kvalitnějších výběrových kritérií kompetenčního modelu (viz text v příloze 2).

Nespornou výhodou metody diskriminační analýzy je to, že umožňuje hlubší vhled do chování matematického modelu a jeho jednotlivých proměnných, a tím také snazší interpretaci výsledků analýzy. Naopak hlavním omezením této metody je (vedle požadovaného množství a typu dat) to, že při řešení klasifikačních úloh dokáže využívat pouze lineárních vztahů mezi sledovanými proměnnými. To znamená, že diskriminační analýza (resp. s její pomocí vygenerovaný matematický model) není vždy tím nejúčinnějším rozpoznávačem a klasifikátorem, protože v komplexním reálném světě jen málokdy platí čistě lineární vztahy a souvislosti (více viz Meloun, Militký, 2004).

Umělé neuronové sítě

V tomto ohledu jsou účinnou alternativou k diskriminační analýze umělé neuronové sítě (*Artificial Neural Networks*), někdy také nazývané konekcionistické modely či PDP systémy, tj. systémy paralelního zpracování informací (*Parallel Distributed Processing Systems*). Jedná se o typ výpočetní architektury inspirované fungováním biologického mozku a o typ adaptivního systému přizpůsobujícího své chování změnám vnějšího prostředí nebo částí systému samotného, a schopného se tak učit a řešit nové problémy na základě předchozích „zkušeností“. Umělé neuronové sítě (dále UNS) jsou nejčastěji využívány v rámci výpočetní kognitivní neurovědy jako nástroj modelování kognitivních funkcí a pak v rámci data miningu jako statistický nástroj, který je citlivý k nelineárním vztahům a souvislostem mezi proměnnými a který umožňuje automatické modelování vstupně-výstupních funkcí (*function modeling*), klasifikaci a rozpoznávání datových vzorců (*classification and pattern recognition*), seskupování dat podle jejich podobnosti (*clustering*), vizualizaci multidimenzionálních dat (*multidimensional data visualization*), predikci časových řad (*time series prediction*), detekci anomálií (*anomaly detection*), komprimaci dat (*feature extraction*), dynamické filtrování dat (*dynamic filtering*) atd.

Nás zde bude zajímat pouze onen druhý zmiňovaný způsob využití umělých neuronových sítí, konkrétně jejich použití jako nástroje klasifikace a rozpoznávání datových vzorců a vizualizace multidimenzionálních dat. Propojením těchto dvou různých funkcí v rámci jedné aplikace by se měl vylepšit profil silných a slabých stránek běžné klasifikační UNS, který je přesně opačný než obdobný profil diskriminační analýzy. Na jednu stranu si UNS dokáže velice dobře poradit s informačním šumem, chybami a nelineárními vztahy nacházejícími se ve vstupních datech, na druhou stranu je ale velice obtížné (a to i pro odborníka, natož pak pro laika) získat vhled do jejího vnitřního fungování a porozumět zákonitostem či vnitřním reprezentacím, na základě kterých generuje své (klasifikační) výstupy. To je dáno tím, že tento specifický typ výpočetní architektury se skládá z poměrně velkého počtu prvků, mezi kterými existuje velké množství nelineárních vztahů, které se

jen velice obtížně rozplétají. Výstižně to charakterizují slova jedněch z „otců zakladatelů“ nové vlny konekcionismu ze začátku 80. let 20. století: „*Jedna věc, kterou spolu mají konekcionistické modely a mozky společnou, je to, že když je otevřeme a nahlédneme dovnitř, vše, co uvidíme, je jen velká hromada nepříjemně lepkavé a vlhké substance.*“¹ (Mozer, Smolensky, 1989, s. 4) V současné době však již existuje řada technik a postupů, které umožňují přímo či nepřímo nahlédnout do samotných „vnitřností“ mechanismu, který produkuje pozorovatelné chování biologického mozku. Kognitivní neurovědci dnes mají k dispozici takové nástroje, jako je magnetická rezonance, metoda evokovaných potenciálů, funkční magnetická rezonance či pozitronová emisní tomografie, které umožňují analýzu strukturálních i funkčních vlastností mozku, tedy analýzu nejen toho, kde se co v mozku nachází, ale také toho, které části mozku jsou aktivní při řešení různých druhů úloh. Analogické techniky lze použít i v případě UNS, navíc s mnohem nižšími náklady a s mnohem větší časovou i prostorovou přesností. K zpracování a analýze takto získaných údajů se většinou používají sofistikované vícerozměrné statistické metody, jako je shluková analýza, multidimenzionální škálování či analýza hlavních komponent – ty umožňují získat hlubší vhled jednak do váhové matice UNS, která má analogickou funkci jako klasický počítačový program, a rovněž do povahy vnitřních reprezentací, jejichž prostřednictvím UNS mění strukturu podobnosti vstupních vzorců aktivace za účelem požadované transformace vstupů na výstupy (a které tak vypovídají o tom, jak UNS těmto vstupům „rozumí“ – ve smyslu jejich ne/podobnosti z hlediska určitého kritéria, které se jí „zdá“ být podstatné pro řešení dané úlohy).

Vzhledem ke své náročnosti se taková zevrubná analýza vnitřní konektivity UNS a způsobu jejího chování realizuje většinou pouze ve výzkumné praxi – v rámci oborů, jako je výpočetní kognitivní neurověda či syntetická psychologie. V běžné komerční praxi se UNS často „po behavioristicku“ považuje za druh černé skříňky, do které z jedné strany přicházejí vstupy a z druhé vycházejí výstupy, a to, co se děje mezi tím, je neproniknutelně zahaleno tajemstvím. Tento přístup však značně omezuje výtěžnost informací a zákonností objevených neuronovou sítí v datech, nemluvě o nedůvěře klienta v něco, o čem de facto ani pořádně neví, jak to funguje.

Samoorganizující mapa výstupního chování klasifikační umělé neuronové sítě

Řešení prezentované v tomto článku se snaží přenést část tohoto analytického přístupu i do komerčního využívání UNS v kontextu práce s lidskými zdroji, a to v takové podobě, ve které by byl snadno přístupný i pro netechnické a nevědecké pracovníky, tedy pro manažery či personalisty. Tímto navrhovaným řešením je propojení dvou různých typů umělých neuronových sítí, každá se svou vlastní specifickou architekturou, vlastním učícím algoritmem a svou vlastní funkcí v rámci jednoho integrovaného systému.

Prvním typem použité UNS je běžná dopředná třívrstevná neuronová síť, skládající se ze vstupní, skryté a výstupní vrstvy uzlů a trénovaná pomocí učícího algoritmu zpětného šíření (*backpropagation learning algorithm*; více viz text v příloze 3). Tento typ UNS je

¹ „*One thing that connectionist models have in common with brains is that when you open them up and peer inside, all you can see is a big pile of goo.*“ (Mozer, Smolensky, 1989, s. 4)

použit k zpracování dat získaných prostřednictvím benchmarkové studie a k vytvoření matematického modelu umožňujícího klasifikaci kandidátů do dvou různých výkonnostních skupin zaměstnanců na základě prezentovaného osobnostního profilu kandidáta či jiných (např. biografických) informací. To, co klasifikační UNS ve své podstatě dělá, je to, že prostřednictvím specificky nastavených vah spoju a prahových funkcí „porcuje“ více-rozměrný stavový prostor vstupních aktivačních vzorců (mající stejný počet dimenzí jako je počet proměnných popisujících jednoho kandidáta) do několika rozhodovacích oblastí (*decision regions*); každý kandidát je pak klasifikován a zařazen do jedné z výkonnostních skupin podle toho, do které z těchto oblastí spadá. Nic z toho však člověk pracující s UNS běžně nevidí. Obvykle vidí pouze to, že se uzel ve výstupní vrstvě UNS v určité míře aktivuje – to v případě, že je UNS na vstupní vrstvě prezentován takový aktivační vzorec (reprezentující osobnostní profil člověka nebo jiné informace o této osobě), který podle jí historicky dostupných dat a objevených zákonitostí odpovídá člověku, který bude na dané pozici úspěšný, nebo že uzel ve výstupní vrstvě naopak mlčí – to v případě, že se jedná o kandidáta nevhodného na danou pozici.²

Druhým typem použité UNS je tzv. Kohonenova samoorganizující mapa (*Self-Organizing Map*, dále SOM) skládající se z obdélníkové mřížky či sítě vzájemně propojených uzlů a trénovaná pomocí kompetitivního učícího algoritmu bez učitele (více viz text v příloze 4). SOM bývá obvykle využívána ke shlukování dat podle jejich podobnosti a k vizualizaci multidimenzionálních dat. Výstupem tréninku SOM je sada topograficky organizovaných map (tzv. mapletů), kde sousedící a prostorově blízké uzly sítě reagují na podobné podněty. SOM tak dává vzniknout jakési době kortikálních topografických reprezentací v primární somatosenzorické či primární sluchové kůře, kde sousedící neurony zpracovávají podněty z prostorově blízkých oblastí těla, resp. blízké frekvence zvukového spektra.

Po natrénování klasifikační UNS je SOM použita ke zmapování a vizualizaci jejího generalizačního gradientu, resp. jejího chování na vstupní a výstupní vrstvě³: Natrénované klasifikační UNS jsou nejdříve na vstupní vrstvě prezentovány všechny možné kombinace hodnot proměnných popisujících jednotlivé kandidáty a zároveň je na její výstupní vrstvě zaznamenána její (kategorizační) reakce na každý z takto prezentovaných profilů; tyto údaje jsou posléze spolu se všemi možnými kombinacemi vstupních proměnných předloženy SOM. Po jejím natrénování vznikne sada map, které mají všechny stejné topografické uspořádání (tzn., že umístění datových bodů – jednotlivých kandidátských profilů – je stejné napříč všemi mapami), ale liší se ve svém výškovém profilu (znázorněném

² V případě zde prezentovaných příkladů je úkolem UNS nejen jednotlivé vstupní aktivační vzorce (reprezentující osobnostní profil a další informace o kandidátovi) klasifikovat do jedné z výkonnostních kategorií, ale také co nejméně je reprodukovat na výstupní vrstvě (která tak obsahuje stejný počet uzlů jako vstupní vrstva plus navíc jeden uzel kódující příslušnost do jedné ze dvou výkonnostních kategorií). Tento typ zapojení (nazývaný prediktivní autokóder, *predictive autoencoder*) je inspirován konekcionistickým modelem hipokampu, podle kterého je jednou z hlavních funkcí této části mozku prediktivní diferenciace reprezentací těch charakteristik, které zvlášť přispívají k predikci požadovaného výstupu, a naopak komprese reprezentací těch charakteristik, které spolu korelují nebo které jsou redundantní a nijak zvlášť nepřispívají k predikci požadovaného výstupu. Důležitým vedlejším produktem tohoto způsobu zpracování informací je to, že UNS dokáže ve vstupních datech objevit jisté zákonitosti, které zvyšují její schopnost generalizace na nové a dosud nepotkané případy (více viz Gluck, Myers, 2001).


³ Pojem *generalizační gradient* je zde převzat z terminologie teorie učení, kde označuje křivku zachycující vliv změny fyzikálních vlastností působícího podnětu na změnu reakce organismu. Obecně platí, že reakce organismu na daný podnět se mění pozvolně (graduálně) v závislosti na míře podobnosti mezi testovacím podnětem a původním tréninkovým podnětem. Generalizační gradient tak poskytuje informaci o míře, v níž organismus vnímá dva různé podněty jako podobné (více viz Gluck, Mercado, Myers, 2007).

pomocí barevné škály) podle typu vstupní či výstupní proměnné, kterou mapa zobrazuje. V tomto ohledu má SOM velice blízko k původní české metodě Sociomapování, která při analýze a vizualizaci vícerozměrných dat pracuje rovněž s výškovým zobrazováním jednotlivých dimenzí do topograficky stejně uspořádaných map (více viz Bahbouh, 2004).

Tímto způsobem SOM dokáže přehledným způsobem reprezentovat vícerozměrný stavový prostor kandidátských profilů spolu s jejich vlivem na výkon na různých pracovních pozicích v uživatelsky vstřícném formátu dvou, resp. tří prostorových dimenzí, ve kterých se člověk dokáže velice dobře a bez jakékoli zjevné námahy orientovat. Využití SOM je tak svého druhu kognitivní zkratkou, která komplexní úlohu relačního usuzování a matematické analýzy převádí na poměrně jednoduchou úlohu zrakové orientace v prostoru. Díky tomu může personalista ze sady několika málo obrázků na monitoru počítače snadno odvodit, jaké jsou charakteristiky těch nejúspěšnějších zaměstnanců na dané pozici a co je odlišuje od těch ostatních; v případě, že do aplikace nejdříve vloží profil posuzovaného kandidáta, může z jednotlivých map snadno zjistit, kde ve stavovém prostoru kandidátských profilů se daný uchazeč nachází, jak si stojí v jednotlivých sledovaných charakteristikách, ke kterým z pracovních pozic má lepší předpoklady a kde je větší pravděpodobnost, že bude úspěšný, v jakých oblastech by se měl zlepšit, aby ve své práci podával lepší výkon, či jaká je nejkratší možná (nebo nejjistější či pro firmu nejméně nákladná) cesta k takové změně. To vše jen prostřednictvím zrakové inspekce několika málo map, případně několika málo kliků na počítačové obrazovce, bez nároků na matematickou gramotnost uživatele a bez dlouhých hodin strávených nad počítačem.

Využití v personalistické praxi

Na následujících řádcích a v několika přílohách je uvedeno pár ukázek aplikace navrženého systému v praxi personalisty fiktivní firmy, která se z vnitřních i externích zdrojů snaží obsadit pozice finančního poradce, obchodního reprezentanta firmy a manažera firemního prodejny. Podkladem uvedených příkladů jsou reálná data a výsledky ze tří nezávislých benchmarkových studií, kde byl ke zjištění relevantních osobnostních charakteristik použit Hoganův osobnostní dotazník (HPI) – vysoce validní psychodiagnostický



Obr. 1 Základní struktura a popis jednoho z mapletů tvořících uživatelské rozhraní navrhovaného nástroje

test, primárně navržený pro použití při výběru zaměstnanců, jejich rozvoji a kariérovém plánování; umožňuje popsat každého člověka na základě sedmi obecných rozměrů osobnosti, které z velké části determinují úspěšnost člověka na nejrůznějších pracovních pozicích, z nichž každá vyžaduje určitý specifický profil vlastností a předpokladů (více viz Wagnerová, 2008). Z důvodu prevence kombinatorické exploze byly před samotným zpracováním dat a vytvořením matematického modelu percentilové skóry jednotlivých škál HPI převedeny na sedmibodovou škálu. I navzdory této redukci informací dosáhly při cross-validizaci všechny tři matematické modely úspěšnosti okolo 90 %.

V příloze 5 je zobrazen soubor několika map, které personalista vidí před sebou na počítačové obrazovce. V horní části se nachází sedm map zachycujících sledované charakteristiky kandidátů – zde skóry na sedmi primárních škálách HPI (v pořadí Stabilita, Sebeprosazování, Sociabilita, Kooperativnost, Systematičnost, Zvídavost, Učenlivost). Těchto prvních sedm map přehledným způsobem zachycuje sedmírozměrný stavový prostor HPI profilů (definovaný všemi možnými kombinacemi hodnot vstupních proměnných, které při použití sedmibodové škály existují, 7⁷, tedy 823 543). Pod souborem těchto sedmi základních map se nachází další tři mapy, které zachycují výkon kandidátů s různým osobnostním profilem na třech různých pracovních pozicích (v pořadí finanční poradce, obchodní reprezentant firmy a manažer firemní prodejny).

Díky stejné topografické organizaci všech deseti map je velice snadné analyzovat **vztahy a souvislosti mezi pracovními pozicemi a osobnostním profilem člověka nebo mezi jednotlivými pracovními pozicemi navzájem**, a to v zásadě pouze prostřednictvím vysoce automatizovaných procesů zajišťujících zřetelnou orientaci v prostoru. Takto je například z relativně podobného tvaru map pro výkon na jednotlivých pozicích patrné, že všechny tři pozice toho mají zřejmě hodně společného (ve smyslu požadavků kladených na zaměstnance), neboť z tvaru tří odpovídajících map se zdá, že je často mohou úspěšně vykonávat lidé se stejným nebo velice podobným osobnostním nastavením. Toto překrytí je přitom obzvláště výrazné v případě prvních dvou map zobrazujících výkon na pozicích finančního poradce a obchodního reprezentanta firmy, což dává docela dobrý smysl, vezmeme-li v úvahu, že se jedná především o prodejní pozice.

V případě, že personalistu budou zajímat **osobnostní charakteristiky těch nejúspěšnějších zaměstnanců na dané pozici** (například za účelem nastavení výběrových kritérií či formulace položek do behaviorálního rozhovoru), může využít skutečnosti, že všech deset map je propojeno, a pomocí několika málo kliknutí na své obrazovce označit oblasti vysokého výkonu na mapě odpovídající pracovní pozici. Díky propojení se automaticky označí stejné oblasti i na všech zbývajících devíti mapách. To jednak personalistovi usnadní orientaci, takže bude mít větší jistotu, že se při vyvozování ideálního profilu dívá na mapě na ta správná místa, ale hlavně mu to umožní si ve speciálním okně zobrazit konkrétní číselné hodnoty a některé základní statistické údaje, které jsou skryté za barevným kódem map a pod označenými uzly sítě. V příloze 6 je soubor map, kde je tímto způsobem zvýrazněna jedna ze tří skupin s vysokým výkonem na pozici manažera firemní prodejny (v pořadí třetí „výkonnostní“ mapa). Již při letném pohledu je zřejmé, že tato vyznačená skupina (nacházející se na „severním“ okraji mapy) se vyznačuje vysokými hodnotami sebeprosazování, sociability a systematičnosti (druhá, třetí a pátá mapa), podprůměrnou kooperativností a zvídavostí (čtvrtá a šestá mapa) a průměrnou emoční stabilitou a učenlivostí (první a sedmá mapa). Tento závěr potvrzují i automaticky generované statistické údaje (v příloze nezobrazené). Podobným způsobem by pak bylo možné postupovat

i u zbývajících dvou skupin úspěšných manažerů firemních prodejen, případně u druhých dvou pracovních pozic.

Další možností, jak personalista může zde představovaný nástroj využít, je jeho přímé využití v situaci **výběru nového zaměstnance** či **umístění stávajícího zaměstnance na novou pozici** při reorganizaci pracoviště. Uchazeč nejdříve vyplní osobnostní dotazník HPI; po jeho vyhodnocení je výsledný osobnostní profil uchazeče vložen do aplikace; to má za následek aktivaci odpovídajícího uzlu sítě na všech mapách. V tomto případě personalistu budou zajímat pouze tři „výkonnostní“ mapy, případně jen jedna z nich. Personalista z nich okamžitě dokáže vyčíst, kde ve stavovém prostoru HPI profilů se uchazeč nachází, ale hlavně to, jaký to má (podle vytvořeného matematického modelu) dopad na jeho schopnost úspěšně zastávat vybranou pozici, případně to, na jakou z pracovních pozic má (opět podle vytvořeného matematického modelu) uchazeč nejlepší předpoklady a kde je nejvyšší pravděpodobnost, že bude úspěšný. V příloze 7 je takto znázorněna situace uchazeče (nacházejícího se v „jihovýchodním“ cípu jednotlivých map, majícího tedy nízkou emoční stabilitu, vyšší sebeprosazování, vysokou sociabilitu a kooperativnost, nízkou systematičnost a zvědavost a vysokou učenlivost), který má podle všeho nejlepší osobnostní předpoklady pro pozici manažera firemní prodejny (třetí „výkonnostní“ mapa), nižší předpoklady pro pozici obchodního reprezentanta (druhá „výkonnostní“ mapa) a pouze minimální pro pozici finančního poradce (první „výkonnostní“ mapa).

Zajímavou oblastí uplatnění popisovaného nástroje je **oblast rozvoje zaměstnanců**. Díky tomu, že personalista ví, kde přesně ve stavovém prostoru HPI profilů se daný zaměstnanec nachází a kde se nachází oblasti vysokého výkonu na dané pozici, může personalista zaměstnanci pomoci naplánovat pomyslný přesun ve stavovém prostoru z oblasti nízkého nebo jen průměrného výkonu do oblasti vysokého výkonu. Jinak řečeno, personalista může s pomocí tohoto nástroje zaměstnanci kvalifikovaně poradit, jak stavět na svých silných stránkách, a jak naopak kompenzovat své slabé stránky vyplývající z jeho osobnostního profilu ve vztahu k dané pracovní pozici. Díky specifickému formátu, ve kterém jsou všechny potřebné informace personalistovi dostupné, dokáže personalista navíc předpovědět, jaká z trajektorií bude nejkratší nebo jaká bude mít nejnižší výškový profil. Personalista vybavený tímto nástrojem tak dokáže snadno přijít s rozvojovými doporučeními, která povedou k požadovanému cíli (vyššímu výkonu na dané pozici) a zároveň budou vyžadovat co nejméně změn nebo změny co možná nejschůdnější, časově (nebo i finančně) nejméně náročné atp. V příloze 8 je takto znázorněna situace zaměstnance, který na pozici obchodního reprezentanta dosahuje pouze podprůměrných výsledků (spodní zvýrazněný uzel v tmavé oblasti na druhé z „výkonnostních“ map). Po identifikaci a vyznačení nejbližšího místa vysokého výkonu (horní zvýrazněný uzel ve světlé oblasti tamtéž) je zřejmé, že u tohoto zaměstnance by bylo vhodné nastavit rozvojový plán takovým způsobem, aby v budoucnu byl více citlivý ke zpětné vazbě („pohyb“ od vysoké k nižší stabilitě na první mapě), aby byl náročnější při stanovování svých obchodních cílů („pohyb“ od nízkého k vyššímu sebeprosazování na druhé mapě), dával více prostoru svým klientům („pohyb“ od vysoké k nižší sociabilitě na třetí mapě), dokázal zaujmout kritičtější a objektivnější postoj k nabízeným produktům („pohyb“ od vysoké k nižší kooperativnosti na čtvrté mapě) a aby si udržoval lepší přehled o novinkách a trendech ve svém oboru („pohyb“ od průměrné k vyšší učenlivosti na sedmé mapě); případně mu můžeme doporučit práci na pozici finančního poradce (vysoká pozice, resp. umístění ve světlé oblasti na první „výkonnostní“ mapě). Na podobném principu může být založeno

rovněž finální **rozhodování mezi dvěma stejně neideálními kandidáty** – personalista může upřednostnit toho kandidáta, který se ve stavovém prostoru nachází blíže oblasti vysokého výkonu, a u kterého tedy existuje předpoklad, že k dosažení vysokého výkonu na dané pozici u něj bude zapotřebí menšího množství rozvojových změn.

Závěr

Všechny výše uvedené příklady pracovaly se třemi pracovními pozicemi a se škálami HPI jako hlavními prediktory výkonu na jednotlivých pracovních pozicích. Navržený nástroj však není ničím z toho jakkoli omezen. Jako prediktory mohou být použita jakákoli jiná data – biografické údaje, výsledky ve výkonnostních testech, chování v reálných situacích, hodnocení nadřízenými či zákazníky atp. Systém lze rovněž poměrně snadno a rychle (po provedení příslušných benchmarkových studií) rozšířit o novou pozici či adaptovat mapu stávající pozice (v případě, že se časem významně změní profil požadavků na její úspěšné vykonávání). Tímto nástrojem tak personalista dostává do rukou flexibilní, snadno aktualizovatelný, a navíc uživatelsky velice vstřícný systém, který mu značně usnadní každodenní rozhodování v personálních otázkách výběru, umístování a rozvoje zaměstnanců. Ale jako u každé podobné metody i zde platí heslo *rubbish in, rubbish out*, tedy že výstupy jsou jen tak kvalitní, jak kvalitní jsou vstupní data. To klade zvýšené nároky na kompetenci osoby realizující benchmarkovou studii a hlavně následné statistické zpracování získaných dat. Do budoucna se proto zatím jako nejhodnější jeví být přenesení břemena této části práce na specializovanou firmu disponující potřebnými znalostmi a zkušenostmi. Užívání finálního produktu by však již jednoznačně mělo být v rukou samotného klienta-personalisty-manažera, neboť jen tak se zajistí, že se plně využije potenciál tohoto nástroje při podpoře a facilitaci manažerova každodenního rozhodování v otázkách personálního řízení.

LITERATURA

- BAHBOUH, R. (2004). *Sociomapování*. Praha: Univerzita Karlova, Filozofická fakulta.
- BENÁK, R. (2003). Bludné kořeny ve výběru nejen manažerů. *HR Fórum*, (9), 24–26.
- CLARK, A. (2001). *Mindware. An Introduction to the Philosophy of Cognitive Science*. New York: Oxford University Press.
- CRNKOVIC, L. (2007). *The Self-Organized Gene (Part 1)*. [Vyhledáno 10. 2. 2009 na <http://blog.peltarion.com/2007/04/10/the-self-organized-gene-part-1/>]
- DAWSON, M. R. W. (2004a). *Connectionism And Psychological Modeling*. Malden: Blackwell Publishers.
- DAWSON, M. R. W. (2004b). *Minds and Machines*. Malden: Blackwell Publishers.
- FANTA, J. (2000). *Neuronové sítě ve společenských vědách*. Praha: Karolinum.
- GLUCK, M. A., MYERS, C. E. (2001). *Gateway to Memory. An Introduction to Neural Network Modeling of the Hippocampus and Learning*. Cambridge: The MIT Press.
- GLUCK, M. A., MERCADO, E., MYERS, C. E. (2007). *Learning and Memory. From Brain to Behavior*. New York: Worth Publishers.
- CHURCHLAND, P. C., SEJNOWSKI, T. J. (1999). *The Computational Brain*. Cambridge: The MIT Press.
- MCLEOD, P., PLUNKETT, K., ROLLS, E. T. (1998). *Introduction to Connectionist Modelling of Cognitive Processes*. New York: Oxford University Press.
- MELOUN, M., MILITKÝ, J. (2004). *Statistická analýza experimentálních dat*. Praha: Academia.

- MOZER, M. C., SMOLENSKY, P. (1989). Using relevance to reduce network size automatically. *Connection Science*, (1), 3–16.
- PLUNKETT, K., ELMAN, J. L. (1997). *Exercises in Rethinking Innateness. A Handbook for Connectionist Simulations*. Cambridge: The MIT Press.
- WAGNEROVÁ, I. (2008). Hoganovy metody v personálně-psychologické praxi. *Psychologie v ekonomické praxi*, (1–2), 47–56.

UTILIZATION OF KOHONEN'S SELF-ORGANIZING FEATURE MAP OF ANN'S GENERALIZATION GRADIENT AS A USER-FRIENDLY TOOL FOR EMPLOYEE RECRUITMENT, PLACING AND DEVELOPMENT

L. STEHLÍK

ABSTRACT

The article refers to a proposal of user friendly and easily adaptable tool which can facilitate and enhance HR managers' decisions in domain of employee recruitment and development. Proposed tool has three main parts: (a) benchmark study of the employee ideal profile, (b) three-layered feedforward artificial neural network (ANN) used for processing benchmark study data and for classification of employees and applicants into two different performance groups and (c) Kohonen Self-Organizing maps enabling visualization of ANN's generalization gradient. User interface of proposed tool is a set of maps with identical topographical organization but with different vertical profile according to displayed variable. HR managers can read very easily and intuitively from these maps important and useful information which can be directly used in the HR related decision making process.

Key words: human resources, benchmark, artificial neural networks, Kohonen self-organizing maps, generalization gradient, multidimensional data visualization

KOHONEN-KARTEN ALS BENUTZERFREUNDLICHES INSTRUMENT ZUR AUSWAHL, POSITIONIERUNG UND FORDERUNG VON ANGESTELLTEN

L. STEHLÍK

ABSTRAKT

Gegenstand des Artikels ist der Entwurf eines benutzerfreundlichen und einfach aktualisierenden Instruments, das den Personalisten die tagtägliche Entscheidung bei der Auswahl, Positionierung und Forderung der Angestellten hilft. Das Instrument kombiniert drei Elemente: (a) Benchmarkstudien des Idealprofils des Kandidaten auf bestimmte Arbeitspositionen, (b) dreistufiges vorwärts vermittelndes künstliches Neuronennetz, das zur Datenanalyse der Benchmarkstudie und Klassifizierung der Angestellten und Kandidaten in zwei verschiedene Leistungsgruppen benutzt wird und (c) Kohonen-Karten, welche die Visualisierung des Generalisierungsgradienten des klassifizierenden künstlichen Neuronennetzes ermöglichen. Die Anwendungsschnittstelle des Instruments hat die Struktur von Karten mit der gleichen topographischen Struktur und unterschiedlichem Höhenprofil entsprechend der abgebildeten Variablen. Aus diesen Karten erkennt der Personalist sehr einfach eine Reihe wichtiger und nützlicher Informationen, die er unmittelbar bei seiner Entscheidung benutzen kann.

Schlüsselwörter: Human Ressourcen, Benchmark, künstliche Neuronennetze, Kohonen- Karten, Generalisierungsgradient, Visualisierung mehrdimensionaler Daten

PhDr. Luděk Stehlík, Vzdělávací společnost EDOST, s.r.o., doktorand Katedry psychologie FF UK v Praze

Autor děkuje firmě Assessment Systems za poskytnutí dat a podkladů k tomuto článku.

Příloha 1 – Benchmarková studie

Užitečnost realizace benchmarkové studie ilustrují dva následující příklady, které ve svém článku „*Bludné kořeny ve výběru nejen manažerů*“ uvádí Rostislav Benák, spolumajitel konzultantské společnosti Assessment Systems, která má dlouholeté zkušenosti s realizací benchmarkových studií pro renomované domácí i zahraniční společnosti.

Typickým zdrojem zkeslení při sestavování kompetenčního modelu je pracovní pozice jeho sestavovatele; takto má např. nadřizený tendenci upřednostňovat a požadovat u svých budoucích podřízených ty charakteristiky, které jsou užitečné pro něj jako nadřízeného, ale nikoli nutně užitečné pro samotný výkon na dané pozici. „*Manažer prodejního týmu popsal svého ideálního kandidáta mimo jiné následovně: „spolehlivý a důsledný“. Při detailním rozboru vyšlo najevo, že má s některými členy současného prodejního týmu opakované problémy s nevyplňováním výkazů o prodejních návštěvách a s včasným odevzdáváním podkladů pro reporting. Za pomoci Hoganova osobnostního dotazníku proběhlo zpracování benchmarku nejlepších dosavadních prodejců daného oddělení. Byla použita měřitelná kritéria a tvrdá data, nikoliv fuzzy dojmy. Vyšlo najevo, že právě u nejlepších prodejců byly tyto charakteristiky zastoupeny nejméně. Spolehlivý a důsledný prodejce by sice precizně vyplňoval tabulky a výkazy, ale pro chybějící tendence být flexibilní a adaptabilní v přístupu k individuálním zákazníkům by jeho prodeje nebyly slavné.“* (Benák, 2003, s. 25)

Výsledná zjištění benchmarkové studie jsou rovněž často protiintuitivní a jdou proti očekáváním a předpokladům „zdravého selského rozumu“. „*Na vojácích francouzského kontingentu, kteří se účastnili mise do Bosny, se pomocí psychodiagnostiky sledoval vztah jejich osobnostního profilu a schopnosti efektivně zvládat dlouhodobý stres. Předpokládalo se, že základní vliv bude mít faktor psychické stability. Mimo všechna očekávání se zjistilo, že vedle tohoto faktoru hraje roli i další faktor – kooperativnost neboli vztah k lidem. Čím nižší hodnota, tím lépe voják snášel stres při nasazení do bojových podmínek, protože na něj kritická situace místního obyvatelstva méně doléhala. A tím lépe a spolehlivěji byl schopen plnit své úkoly. Zpracovaný benchmark byl dán jako doporučení pro výběr dobrovolníků do podobných misí.“* (Benák, 2003, s. 26)

Příloha 2 – Diskriminační analýza

Při realizaci benchmarkové studie pro jednu nejmenovanou finanční instituci byl za účelem predikce budoucího výkonu na pozici finančního poradce za použití Hoganova osobnostního dotazníku (HPI) a s pomocí diskriminační analýzy vytvořen následující matematický model (s úspěšností okolo 90 % u tréninkového vzorku a 85 % úspěšností při cross-validizaci):

$$\text{PREDIKTOR} = -5,86 + 0,926 * \text{Ne-spontánnost} + 0,019 * \text{Sebeprorazování} + 0,072 * \text{Administrativní potenciál} + 0,104 * \text{Schopnost vést} + 0,055 * \text{Soutěživost} + 0,518 * \text{Matematické schopnosti} - 0,679 * \text{Zvládnutá impulzivita} + 0,735 * \text{Identita}$$

Z něj je i pro jen trochu poučeného laika patrné, jaké osobnostní charakteristiky facilitují výkon na pozici finančního poradce, a jak tedy vypadá ideální osobnostní profil kandidáta na tuto pozici. Mělo by se jednat o člověka, který má vyšší míru sebeprorazování, je ochotnější přebírat vedení ve skupině, je soutěživější, ambicióznější a vytrvalejší, má větší touhu uspět, uskutečňovat věci, mít význam a podávat lepší výkon než konkurence, více si cení

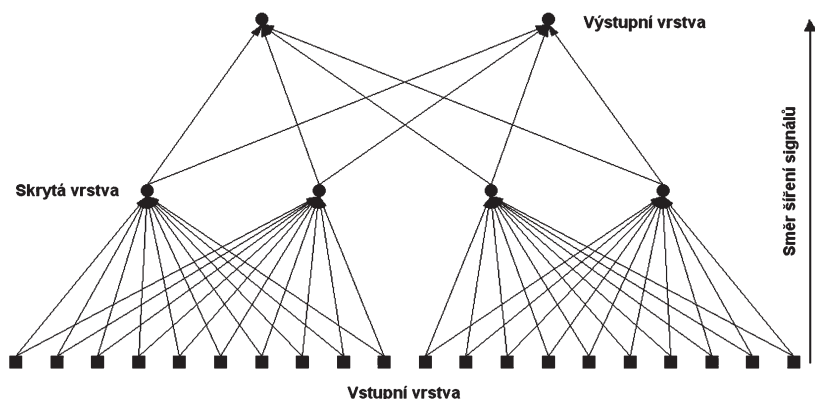
možnosti s druhými soupeřit a porovnávat se s nimi, je více identifikován se svými životními rolami, spíše ví, čím chce být a co chce od života. . . , je více impulzivní, častěji dělá věci pod vlivem okamžiku, nebojí se jít do určitého rizika, na druhou stranu nemá problém s plánováním a organizováním svých pracovních i osobních záležitostí a má vyšší administrativní potenciál (je tedy schopen plnit svěřené úkoly, všimnout si detailů, jasně a přesně komunikovat, je emočně stabilnější a vyrovnanější, lépe se vyrovnává s psychickým tlakem a emočně vypjatými situacemi, nenechá se snadno vyprovokovat, je kultivovaný ve svém jednání).

Takto získané informace lze přitom využít několika různými způsoby. Personalista např. může přímo využít matematický model, do kterého pouze dosadí výsledky, kterých kandidát dosáhl v osobnostním dotazníku HPI. V případě, že personalista nebude chtít utrácet peníze za administraci osobnostního dotazníku, může použít odvozený ideální profil kandidáta k nastavení otázek behaviorálního rozhovoru či k výběru jiných metod, které mu umožní kvalifikovaně odhadnout relevantní dimenze osobnosti. Získané informace přitom nemusí být použity pouze v situaci výběru nových zaměstnanců, ale také v situaci rozvoje těch stávajících, kteří na pozici finančního poradce nedosahují (ve srovnání se svými kolegy- „premianty“) optimálních výsledků. Na základě porovnání reálného profilu finančního poradce s tím ideálním může totiž personalista snadno odhalit silné a slabé stránky zaměstnance (vzhledem k požadavkům pozice finančního poradce) a odpovídajícím způsobem nastavit směr jeho dalšího vzdělávání a rozvoje.

Příloha 3 – Umělé neuronové sítě

Umělé neuronové sítě se skládají – podobně jako biologický nervový systém – ze dvou základních komponent: z jednoduchých procesorů a z vážených (různě efektivních) spojů mezi těmito procesory. V biologickém nervovém systému se jednoduché procesory nazývají neurony a vážené spoje mezi nimi pak axony a synapse. V konekcionistických modelech se tyto základní komponenty nazývají jednotky (*units*) či uzly (*nodes*), resp. spoje (*connections*). Každý jednotlivý uzel přijímá vstupní informace z určitého počtu sousedních uzlů; na základě sumace takto přijatých vstupních informací a na základě určité jednoduché (většinou nelineární) matematické (tzv. aktivační nebo také převodní) funkce následně vypočítá výstupní informaci o míře své aktivace, kterou odešle prostřednictvím váženého spoje k uzlům, se kterými je náležitým způsobem propojen. Takto odeslaná informace pak slouží jako vstup do výpočetní procedury dalších neuronů, které počítají svou vlastní míru aktivace na základě míry aktivace sousedních uzlů, se kterými jsou propojeny prostřednictvím vážených spojů. Váhy těchto spojů přitom mohou být buď pozitivní (excitační), nebo negativní (inhibiční). Signál, který uzel takto na svém vstupu přijímá, je tedy vždy funkcí míry aktivace sousedních uzlů a vah spojů, po kterých se k němu signály o míře aktivace sousedních uzlů šíří. Typickým (ale ne jediným) uspořádáním uzlů je tzv. třívrstevná dopředná neuronová síť (*three-layered feedforward neural network*), která se skládá ze tří vrstev neuronů (vstupní, skryté a výstupní) a ve které se informace o míře aktivace jednotlivých uzlů šíří vždy pouze jedním směrem, a to od vstupní vrstvy k vrstvě výstupní (viz obrázek).

Zpracovávání informací v neuronové síti probíhá prostřednictvím šíření signálů (o míře aktivace jednotlivých uzlů) po vážených spojích mezi jednotlivými uzly. Správným způsobem modulovaný tok signálů v neuronové síti s tou správnou architekturou (tj. se správným počtem uzlů a s jejich správným zapojením) je přitom schopen implementovat jakoukoli




Obr. 2 Dopředná třívrstevná umělá neuronová síť

vstupně-výstupní funkci. Tok signálů v neuronové síti – vedle její architektury – moduluji především váhy jednotlivých spojů mezi uzly sítě. Váhy spojů fungují jako jakási stavidla, která požadovaným způsobem omezují a regulují tok mediační látky, která nese informaci o míře aktivace jednotlivých uzlů sítě. Tok mediační látky neuronovou sítí je takto „vytvárován“ do podoby, kterou mu diktují různá omezení v podobě vah spojů mezi uzly sítě. Z toho vyplývá, že k implementaci požadované funkce je vždy potřeba nalézt vhodným způsobem nastavené váhy spojů. Vzhledem k obrovskému počtu spojů v neuronových sítích je prakticky nemožné nastavovat jejich váhy „ručně“; proto se k nalezení požadované váhové matice využívají různé automatizované mechanismy – tzv. učící či tréninkové algoritmy, které prohledávají stavový prostor množiny všech možných váhových matic dané neuronové sítě a snaží se v něm nalézt takovou váhovou matici, která by dokázala usměrnit tok signálů mezi uzly sítě způsobem umožňujícím požadovanou transformaci vstupů na výstupy. Jedním z nejčastěji používaných učících algoritmů je některá z verzí tzv. delta pravidla, které mění váhy spojů mezi jednotlivými výpočetními jednotkami v souladu se zpětnou vazbou, kterou neuronová síť dostává z vnějšího prostředí o svém aktuálním výkonu. V typickém případě začíná neuronová síť s náhodně nastavenými vahami spojů, takže náhodná je také odpověď, kterou neuronová síť dává na své výstupní vrstvě na daný podnět; učící algoritmus automaticky počítá velikost rozdílu mezi aktuálním a požadovaným výstupem a tuto informaci používá k výpočtu mírné úpravy vah spojů tak, aby se výkon neuronové sítě při příští prezentaci stejného podnětu zlepšil, tj. aby se rozdíl mezi aktuálním a požadovaným výstupem zmenšil. Tato procedura se provádí se všemi vstupně-výstupními dvojicemi, které chceme, aby se neuronová síť naučila. Celý proces se pak mnohokrát opakuje. V ideálním případě si takto neuronová síť osvojí soubor vah spojů mezi jednotlivými uzly sítě, který jí umožní provádět požadované transformace vstupů na výstupy. Schopnost neuronové sítě produkovat na základě vstupních informací odpovídající výstup takto není výsledkem pečlivého naprogramování nějakého lidského programátora, ale spíše výsledkem její vlastní schopnosti se učit, tedy najít tu správnou váhovou matici, ve které jsou implicitně zakódovány všechny znalosti, které potřebuje k tomu, aby dokázala vyřešit daný problém (více viz Clark, 2001; Dawson, 2004a, 2004b; Fanta, 2000; Churchland, Sejnowski, 1999; McLeod, Plunkett, Rolls, 1998; Plunkett, Elman, 1997).

Příloha 4 – Kohonenova samoorganizující mapa


Kohonenova samoorganizující mapa (*Self-Organizing Map*, dále SOM) je druh umělé neuronové sítě, která je využívána k vizualizaci vícerozměrných dat a ke shlukování dat podle míry jejich podobnosti. SOM se v typickém případě skládá z obdélníkové či čtvercové sítě vzájemně propojených uzlů a je trénována pomocí kompetitivního učícího algoritmu bez učitele (*unsupervised competitive learning algorithm*). Hlavním cílem jejího trénování je to, aby blízké části sítě reagovali na podobná vstupní data podobným způsobem; vedlejším produktem je pak vznik dvourozměrné mapy vícerozměrných vstupních dat, která přitom zachovává jejich topologické vlastnosti. Učící algoritmus používaný k trénování SOM vychází z předpokladu, že uzly sítě jsou speciálním typem datových bodů, které se dokážou pohybovat směrem k běžným statickým datovým bodům. Před začátkem tréninku jsou váhy spojů jednotlivých uzlů nastaveny čistě náhodně. SOM jsou posléze prezentovány jednotlivé vstupní vektory. U každého takového vstupního vektoru je spočítána euklidovská vzdálenost k váhovým vektorům všech uzlů sítě. U vítězného uzlu s nejpodobnějším váhovým vektorem (a tedy s nejsilnější aktivací při prezentaci daného vstupního vektoru) a u několika prostorově nejbližších uzlů sítě jsou jejich váhové vektory pozměněny tak, aby byly podobnější vstupnímu vektoru (a aby tak při příští prezentaci stejného vstupního vektoru vykazovaly silnější aktivaci). Velikost této změny přitom klesá s časem a se vzdáleností od vítězného uzlu. Tento proces se mnohokrát opakuje pro každý ze vstupních vektorů. Na konci tréninkového procesu je takto každý z uzlů sítě spojen se skupinou podobných vstupních dat. Přestože síť uzlů SOM je sama o sobě dvourozměrná, jednotlivé uzly sítě (resp. jejich váhové vektory) mají stejný počet dimenzí jako vstupní data. Na obrázku 3 je vidět příklad takové dvourozměrné SOM pokrývající třírozměrný prostor vstupních dat (s proměnnými X, Y a Z): SOM má stále podobu plochy, každý z jejích uzlů je však umístěn v třírozměrném prostoru.



Obr. 3 Dvourozměrná plocha SOM nacházející se v třírozměrném prostoru vstupních dat


Stejný princip platí i v případě mnohem většího počtu rozměrů, což je důvod, proč je SOM velice užitečná pro vizualizaci vícerozměrných dat. Samotný proces vizualizace ilustruje následující příklad (Crnkovic, 2007). Předpokládejme, že máme SOM s 3 x 3 uzly ve čtvercové síti, která byla trénována na dvourozměrném datovém souboru s proměnnými X a Y (obrázek 4).

Buňky odpovídající jednotlivým uzlům sítě pak můžeme vybarvit podle hodnoty proměnných jednotlivých datových bodů spojených s daným uzlem sítě. Tímto způsobem



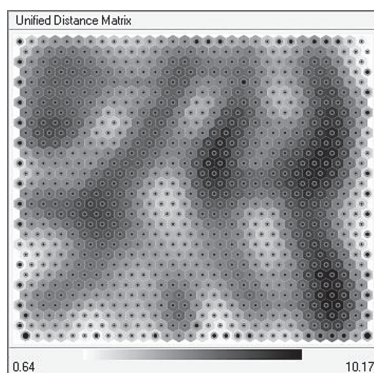
Obr. 4 3 x 3 SOM trénovaná na dvourozměrném souboru dat (Crnkovic, 2007)

vytvoříme dvě mapy (tzv. maplety) zachycující hodnoty proměnné X a Y (obrázek 5). Z nich lze potom velice snadno vyčíst vztahy mezi oběma proměnnými, např. že vysoké hodnoty proměnné Y (světlé oblasti v mapletu Y) se pojí s nízkými hodnotami proměnné X (tmavé oblasti v mapletu X) a obráceně.



Obr. 5 Maplety zachycující proměnné X a Y

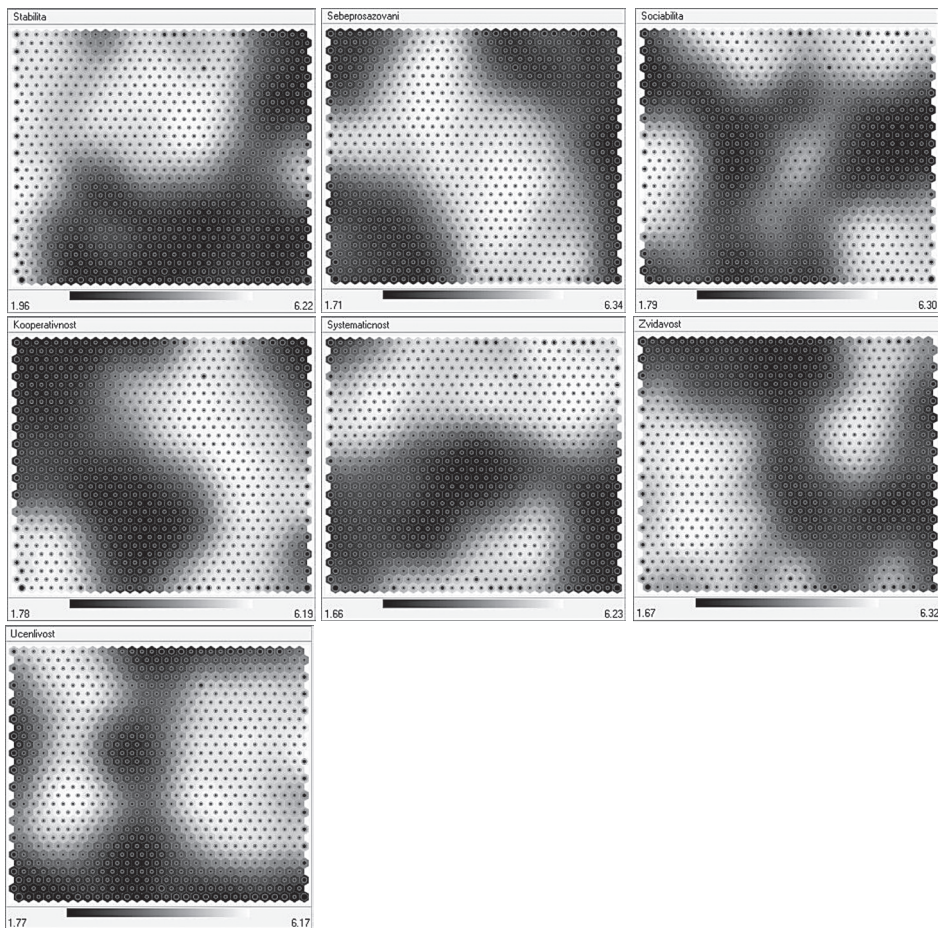
Aplikací celého postupu na samotné uzly natrénované SOM se lze dopracovat k informaci o existenci přirozeně se vyskytujících shluků podobných dat ve vstupním datovém souboru, a to v podobě speciálního druhu mapy, která zobrazuje nikoli hodnotu jednotlivých uzlů pro vybranou proměnnou, ale průměrnou vzdálenost mezi sousedícími uzly sítě. Na obrázku 6 je příklad takové mapy, na které tmavé oblasti označují ty části, kde jsou vzdálenosti mezi uzly velké, a světlé oblasti ty části, kde se uzly nacházejí naopak blízko sebe.




Obr. 6 Maplet zachycující průměrné vzdálenosti mezi jednotlivými uzly sítě

Příloha 5 – Základní schéma, porovnání jednotlivých pracovních pozic

Sledované charakteristiky kandidátů (v pořadí Stabilita, Sebeprazosování, Sociabilita, Kooperativnost, Systematičnost, Zvidavost, Učenlivost)




Výkon na vybraných pracovních pozicích (v pořadí finanční poradce, obchodní reprezentant firmy, manažer firemní prodejny)




Příloha 6 – Analýza ideálního profilu kandidáta

Sledované charakteristiky kandidátů (v pořadí Stabilita, Sebeprazosování, Sociabilita, Kooperativnost, Systematičnost, Zvědavost, Učenlivost)




Výkon na vybraných pracovních pozicích (v pořadí finanční poradce, obchodní reprezentant firmy, manažer firemního prodeje)




Příloha 7 – Výběr a umisťování zaměstnanců

Sledované charakteristiky kandidátů (v pořadí Stabilita, Sebepraznování, Sociabilita, Kooperativnost, Systematičnost, Zvědavost, Učenlivost)

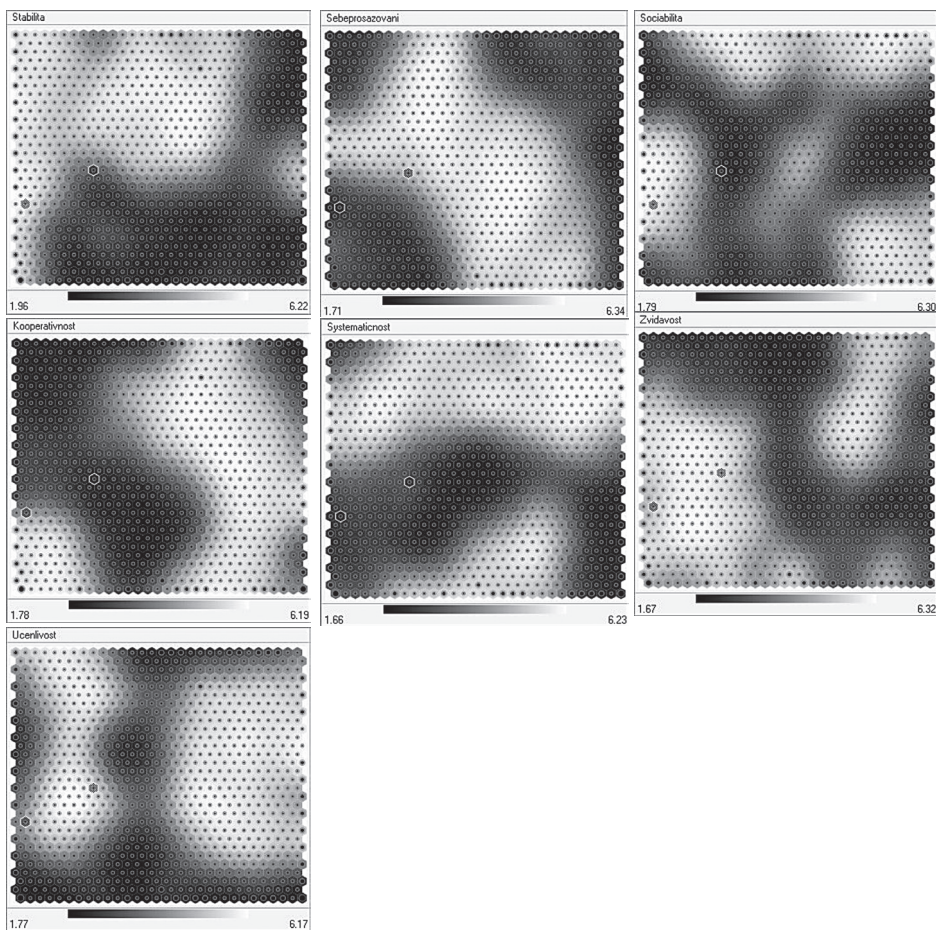


Výkon na vybraných pracovních pozicích (v pořadí finanční poradce, obchodní reprezentant firmy, manažer firemního prodejny)



Příloha 8 – Rozvoj zaměstnanců

Sledované charakteristiky kandidátů (v pořadí Stabilita, Sebeprazosování, Sociabilita, Kooperativnost, Systematičnost, Zvidavost, Učenlivost)



Výkon na vybraných pracovních pozicích (v pořadí finanční poradce, obchodní reprezentant firmy, manažer firemní prodejny)

