

Model vrstevnatých neuronových sítí je známý především díky své univerzální aproximační schopnosti. Již základní algoritmus zpětného šíření dává výsledky použitelné v reálných aplikacích. Efektivní řešení složitých úloh by však mělo vyhovovat náročným požadavkům na rychlost procesu učení a na transparentní strukturu vytvořené sítě. Ta totiž souvisí s lepší schopností sítě zobecňovat extrahované znalosti a následně i se snazší interpretací funkce naučené sítě. Lepšího zobecňování lze dosáhnout použitím různých technik, jako je např. učení s nápovědou, prořezávání a analýza citlivosti. Mezi rychlé algoritmy učení pak patří metody konjugovaných gradientů. V první části této práce jsme shrnuli a navzájem porovnali výše zmíněné techniky. Následně jsme odvodili novou metodu, která v sobě spojuje výhody předchozích technik. Navržený algoritmus je inspirovaný extrémně rychlou metodou škálovaných konjugovaných gradientů. Původní metodu jsme však rozšířili o vynucovanou kondenzovanou interní reprezentaci a prořezávání motivované citlivostní analýzou. Vlastnosti navržené techniky jsme otestovali na umělých úlohách i na reálných datech ze Světové banky. Doposud provedené experimenty naznačují slibné výsledky nového přístupu. Navržená technika dává ve všech ohledech mnohem lepší výsledky než jednotlivé původní metody a výsledky porovnatelné s původními metodami, pokud sledujeme jen jejich nejlepší vlastnost (rychlost učení, schopnost zobecňovat, počet použitých skrytých a vstupních neuronů).