

6.6 Ostatní aplikace UNS

Na tomto místě si uvedeme, pouze přehledově, další možné aplikace UNS. Jsou to:

- **Rozpoznání ručně i strojově psaného písma.** Tato aplikace může sloužit např. pro ověřování podpisu. Pro tuto úlohu je vhodná MLNN s některou variantou učení BPG. Předpokládáme, že existují jedinečné vztahy mezi výškou a šířkou písmen abecedy psaných rukou nějakou osobou. Příklad v podobě písmen H a E je znázorněn na obrázku (6.23). Obě písmena jsou charakterizována sedmi příznaky. Jsou to:

$p_1 = h_1$... absolutní výška H

$p_2 = h_2$... výška k příčné čáře H

$p_3 = h_3$... šířka H

$p_4 = e_1$... absolutní výška E


$p_5 = e_2$... šířka dolní čáry E

$p_6 = e_3$... šířka střední čáry E


$p_7 = e_4$... šířka horní čáry E

Podobně lze postupovat a získat vstupní data i pro další písmena. Dolní hranice počtu vzorků písmen je kolem 30 (pro jedno písmeno). Pokud by rozpoznávač měl generalizovat (odlišit osoby určené pro trénink od ostatních osob), je třeba natrénovat síť alespoň na 10 osob. K rozpoznání identity stačí síťnatrénovat na 5 osob. Neuronová síť má ve vstupní vrstvě počet neuronů rovný počtu příznaků, počet výstupů z UNS je roven počtu osob, na které je trénována. Aktivační funkce mohou být lineární i nelineární. Neuronová síť může mít dvě skryté vrstvy. Jedna z možných variant topologie neuronové sítě pro popisovanou úlohu rozpoznání písmen H a E má počet neuronů dán schématem 7 – 25 – 19 – 5.

- **Kompresí signálů.** Pro tuto úlohu je rovněž vhodné použít síť typu MLNN. Od aplikací pro klasifikaci nebo predikci se však topologie liší. Příklad takové neuronové sítě je znázorněn na obrázku (6.24). Používá se pro kompresi a současné zakódování signálů pro přenosové systémy. Na obou koncích přenosových cest jsou umístěny zrcadlově stejné konfigurace sítě.
- **Filtrace šumu.** Pro tuto úlohu je možné použít oba zde popisované typy neuronových sítí, tedy MLNN i SOM. Pokud použijeme učení



Obrázek 6.23: Příklad získání dat pro rozpoznání ručně psaného písma.



Obrázek 6.24: Příklad topologie MLNN pro kompresi signálů.

s učitelem, pak při trénování bude na vstupu zašuměný signál, který je složen z užitečného signálu a z šumu. Požadovaným výstupem je signál nezašuměný. Při testování resp. simulaci pak na výstupu získáme signál zbavený rušivých složek. Tento způsob je vhodný pro bílý šum, při změně druhu šumu je nutné neuronovou síť přetrénovat.

MLNN je možné také použít k odhadu hladiny poměru signál/šum resp. k odhadu hladiny šumu ve větě, k odhadu amplitudy šumu u narušené řeči a k odečtu vektoru šumu. Tyto postupy přinášejí zlepšení rozpoznání. Přesto zůstává redukce šumu před vlastním rozpoznáváním velmi sledovanou oblastí výzkumu, zvláště v aplikacích, kde šum je nestacionární nebo je korelovaný s řečovým signálem (např. ozvěna řeči v jedoucím autě).

- **Diagnostika chyb.** Průmyslová zařízení jsou obvykle velmi složité systémy, popsatelné stavovými proměnnými, často v nelineárním prostředí. V jejich funkci ale existuje mnoho charakteristických stavů, které je možné sloučit do skupin, tříd. Protože SOM je ve své podstatě nelineární projekční metoda, mohou být tyto stavy viditelné v SOM, a to bez nutnosti explicitního modelování systému. Detekce chyb může být založena na určení kvantizační chyby. Pokud totiž nejmenší ze vzdáleností mezi vektorem příznaků a všemi referenčními vektory v mapě překročí předem zvolenou hodnotu, ukazuje to na špatný průběh sledovaného procesu. Tato úvaha je založena na předpokladu, že velká kvantizační chyba odpovídá pracovnímu bodu, který patří do jiného prostoru, než jsou trénovací data.