

Fuzzy neuronové řídicí systémy – vysvětlení

-- 01.12.07

Neuronové sítě a fuzzy logika mohou řešit problémy řídicího systému, s kterými si tradiční systémy nevedí rady. Přečtěte si, jak fungují a jak mohou být užitečné pro aplikace, jako je vysokorychlostní zpracování obrazu.

Zatímco měli technici v automatizační komunitě co dělat při migraci z tradičních elektromechanických a analogových elektronických technologií na digitální mechatronické řídicí systémy, využívající počítačové analytické a rozhodovací algoritmy, na obzoru se objevily nové počítačové technologie, které mohou situaci změnit ještě více. Neuronové sítě a fuzzy logika se již začaly využívat a mohou rychle převrátit vzhůru nohama metody, jakými jsou systémy řízení strojů navrhovány a programovány.

Tradiční počítače mají von Neumannovskou architekturu, která je založena na sekvenčním zpracování a provádění explicitních instrukcí. Umělé neuronové sítě naproti tomu využívají jinou než von Neumannovskou architekturu. Sestávají z velice jednoduchých zpracovatelských jednotek, propojených do masivního paralelního systému, fungujícího podle implicitních instrukcí na základě rozpoznání vzorců v datových vstupech z externích zdrojů.

Obdobně i fuzzy logika staví tradiční způsob uvažování na hlavu. Namísto informací sestávajících z přesných měření kvantifikujících polohu v unikátně definovaných rozměrech (například „teplota 23° C“), fuzzy informace představuje míru příslušnosti do neurčitě definovaných překrývajících se množin („spíše chladnější teplo“).

Definice

Počítače (nebo přesněji „inferenční stroje“) využívající tyto koncepce se osvědčují při zvládání náročných situací řídicího systému, s kterými si tradiční systémy nevedí rady.

Umělá neuronová síť je podle Wikipedie „propojená skupina umělých ‚neuronů‘, která používá matematický nebo výpočetní model pro zpracování informací na základě konekcionistického přístupu k výpočtu“.


Ve většině případů je umělá neuronová síť adaptivním systémem, který mění svou strukturu na základě externích nebo interních informací protékajících přes síť. Nejpraktičtější je, že umělé neuronové sítě modelují komplexní vztahy mezi vstupy a výstupy nebo nalézají vzorce v datech namísto toho, aby jen produkovaly numerické výsledky na základě numerických vstupů.

Jednoduché uzly (označované různě, „neurony“, „neurody“, „zpracující elementy“, nebo „jednotky“) jsou vzájemně propojeny do sítě uzlů. Jejich užitečnost je dána schopností ztělesnit inferenční algoritmy, které mění síly nebo váhy síťových spojení za účelem dosažení požadovaného toku signálu.

Nejzajímavější je možnost učení, což v praxi znamená optimalizaci určitého množství možných řešení problémů, často označovaného jako „náklad“ (cost), které představuje výhodnost výsledků s ohledem na daný kontext problému. Například nákladem v klasickém problému cestujícího obchodníka je čas potřebný pro objetí celého prodejního teritoria, zastavení na všech požadovaných místech a návrat na výchozí místo. Kratší cesta znamená lepší řešení.

Pro vyřešení tohoto problému musí von Neumannovské počítače identifikovat všechny možné trasy, poté všechny tyto trasy projet samostatně a připočítávat časové nároky, a takto určit celkovou časovou náročnost této trasy. Po vypočtení celkových časů všech tras počítač jednoduše vybere tu

Architektura umělé neuronové sítě



Zdroj: IDIAP Research Institute a Control Engineering

nejkratší.

Naproti tomu umělá neuronová síť se na všechny trasy dívá paralelně a hledá vzorce, které minimalizují celkovou časovou náročnost trasy. Uplatnění těchto vzorců pak minimalizuje výslednou trasu. Učení je tvořeno definováním vzorců, které podle zkušeností poskytují strategie pro optimalizaci trasy.

Fuzzy logika (opět podle Wikipedie) je odvozena z teorie fuzzy množin, která pracuje spíše s přibližnou než precizní logikou. Fuzzy „pravda“ představuje členství v neurčitě

definovaných množinách. Fuzzy logika může přijímat rozhodnutí na základě nepřesně definovaných, ale přitom stále velmi důležitých charakteristik. Fuzzy logika používá hodnoty členství v množinách od 0 do 1 včetně, a neurčité koncepty, jako je „mírně“, „celkem dost“ a „hodně“. Konkrétně umožňuje například částečné členství v množině.

V tomto příkladu umělé neuronové sítě závisí trojrozměrná vektorová proměnná h na vstupní proměnné x . Následně dvojrozměrná vektorová proměnná g závisí na h a nakonec výstupní proměnná f závisí na g .

Základní aplikace může charakterizovat intervaly spojité veličiny. Například měření teploty u protiblokovacího systému brzd může mít několik samostatných funkcí členství, definujících určité teplotní rozsahy potřebné pro správné řízení brzd. Každá funkce mapuje stejnou hodnotu teploty na hodnotu „pravda“ v intervalu 0 až 1. Tyto hodnoty pravdivosti lze poté použít pro určení způsobu řízení brzd.

Zpracování obrazu

Umělá neuronová síť rozhodující na základě fuzzy logiky může vytvořit výkonný řídicí systém. Je zřejmé, že tyto dvě koncepty spolu dobře spolupracují: inferenční algoritmus se třemi fuzzy stavy (například chladno, teplo, horko) může být do hardwaru implementován pomocí hodnot pravdivosti (0,8; 0,2; 0,0) jako vstupů do tří neuronů, přičemž každý z nich zastupuje jednu ze tří množin. Každý neuron poté uplatní na svou vstupní hodnotu funkci, která poskytne výstupní hodnotu, kterou lze pak použít jako vstup pro druhou úroveň neuronů atd.


Například obrazový procesor na bázi neuronové sítě může z aplikací odstranit četné překážky, pokud jde o pořízení videa, osvětlení a nastavení hardwaru. Tento stupeň volnosti je možný díky tomu, že neuronové sítě vám dovolují vybudovat nástroj (engine) učení se na příkladech. V důsledku toho jej lze naučit rozpoznávat dobré a špatné díly za silného i slabého osvětlení, při natočení různými směry apod. Inferenční nástroj začne „vyhodnocením“ světelných podmínek (jinak řečeno, přiřazením hodnot podobnosti – afinity – různým světelným podmínkám, se kterými systém umí zacházet) a následným uplatněním kritérií na základě těchto světelných podmínek pro rozhodnutí o obsahu obrazu. Protože systém pracuje se světelnými podmínkami jako s fuzzy koncepty,

inferenční nástroj přirozeně interpoluje mezi známými podmínkami, aby mohl pracovat s podmínkami novými.

Čím více příkladů se systém naučí, tím je nástroj dovednější. Může být poměrně snadné zautomatizovat tento proces učení například předběžným vytříděním dílů do množin v podobné kategorii pro účely učení rozpoznávání podobností a rozdílů. Takto pozorované podobnosti a rozdíly mohou poté sloužit jako výchozí informace pro umělou neuronovou síť, jejímž úkolem je třídit přicházející díly do těchto kategorií. Klíčem k úspěchu už není cena zařízení, ale počet obrazů potřebných pro vyškolení a vybudování robustního nástroje.

Obrazový procesor na bázi neuronové sítě je vhodný pro aplikace, kde se diagnostika opírá o

Datová struktura fuzzy logiky



Zdroj: Wikipedie a Control Engineering

zkušenosti a dovednosti operátora spíše než o modely a algoritmy. Procesor může vybudovat rozpoznávací nástroj na základě jednoduchých poznámek na obrazu provedených operátorem, a poté extrahovat charakteristiky nebo charakteristické vektory z označených objektů a odeslat je do neuronové sítě. Charakteristickými vektory, popisujícími vizuální objekty, mohou být pouhé hrubé pixelové hodnoty, histogram nebo rozdělení intenzit, profily intenzity nebo gradienty podél relevantních

os. K pokročilejším charakteristikám patří využití metod vlnové a rychlé Fourierovy transformace (součásti vln – wavelet – a hodnoty Fourierovy transformace).

Tento diagram ukazuje na teplotní stupnici množiny chladno, teplo a horko. Bod na této stupnici má tři „hodnoty pravdivosti“ – jednu pro každou ze tří množin, které ukazují na relativní „příslušnost“ ke každé množině. Pro danou zobrazenou teplotu mohou být tři pravdivostní hodnoty (0,8; 0,2; 0,0) interpretovány jako popis teploty, řekněme „poměrně chladno“, „mírně teplo“ a „není horko“.

Zobecňování

Jakmile se neuronová síť naučí na příkladech, je schopná zobecnění a může klasifikovat situace, s kterými se nikdy nesetkala tím, že je asociuje s podobnými naučenými situacemi. Na druhou stranu, pokud má nástroj tendenci být příliš liberální a situace příliš zobecňovat, je možné jej kdykoliv opravit naučením jej příkladům opačného charakteru.

Z hlediska neuronové sítě tato operace sestává z omezení vlivových polí stávajících neuronů tak, aby se přizpůsobily novým příkladům, které jsou v rozporu se stávajícím mapováním rozhodovacího prostoru.

Klíčem k přijetí umělé neuronové sítě je adaptivní učení se bez dozoru. To znamená, že zařízení se musí umět naučit objekt jen s minimálním nebo žádným zásahem obsluhy. Například panenky budoucnosti mohou mít schopnost naučit se, jak vypadá tvář dítěte, které je poprvé rozbaluje, a

zeptat se na jeho jméno. Příkladem bezzásahového učení u mobilního telefonu může být například naučení se otisků prstů jeho prvního uživatele. Autentizace vlastníka může být posílena také kombinací rozpoznání tváře, otisku prstů a hlasu v jediném zařízení.

V kontextu bezzásahového učení si zařízení musí vybudovat svůj vlastní rozpoznávací nástroj, který bude v jeho daném pracovním prostředí fungovat nejlépe. Například inteligentní panenka musí rozpoznat svou první majitelku, bez ohledu na barvu její kůže a vlasů, místo a roční období.

Nástroj musí nejprve využít všechny způsoby extrakce charakteristických vlastností, které umí. Bude generovat řadu dílčích nástrojů, každý určený pro identifikaci stejných kategorií objektu, ale na základě pozorování různých charakteristik (barva, zrnitost, kontrast, hustota okrajů apod.). Globální nástroj pak může vyhodnotit dílčí nástroje a vybrat ty, které poskytují nejlepší průchodnost a/nebo přesnost.

Příklad – třídění ryb

Společnost Pisces VMK vyrábí zařízení na zpracování ryb pro aplikace na palubě lodi i v příbřežních závodech. Jejími zákazníky jsou lodě zpracovávající ryby, vydávající se na celoroční expedice za nejrůznějšími rybími druhy v Severním moři a Atlantickém oceánu. Tito uživatelé chtějí mít své podpalubí co nejdříve naplněno úlovkem nejvyšší kvality pomocí co nejmenšího počtu pracovníků.

Typická situace vypadá tak, že ryby jsou vytaženy na palubu v sítích a vykládány do přihrádek na dopravníkovém pásu vedoucím k čistícím, porcovacím a filetovacím strojům. K anomáliím patří nesprávné druhy, poškozené ryby, přítomnost více než jedné ryby v přihrádce a nevhodná poloha ryby před vstupem do porcovacího stroje. Takovou kontrolu není snadné realizovat pomocí tradičních nástrojů pro zpracování obrazu, z důvodu velikosti, tvaru a škály ryb, které je obtížné modelovat matematicky. Tyto vlastnosti se mohou měnit podle místa expedice a ročního období.

Společnost Pisces nainstalovala přes 20 systémů založených na inteligentní kameře Iris společnosti Matrox a rozpoznávacím nástroji Cogni- Sight společnosti General Vision. Kamera je nainstalována nad dopravníkem tak, že ryby pod ní procházejí těsně před vstupem do filetovacího stroje. Je napojena na programovatelný automat (PLC) Siemens Simatic S7-224 CPU a lokální síť (LAN). Pokaždé, když se nová přihrádka objeví v jejím zorném poli, spustí se zábleskové světlo namontované vedle kamery. Připojení kamery k síti LAN je zapotřebí pro tři operace: nastavení senzoru pro zaostření a dobrý kontrast obrazu, vyškolení rozpoznávacího nástroje a přístup ke statistickým údajům průběžně vykazujícím počet přijatelných a nepřijatelných ryb.

Nastavení senzoru se provádí jen jednou: při instalaci kamery do vodotěsného pouzdra. Školení se provádí na začátku každé expedice buď učením se na příkladech prvně chycených ryb, nebo nahráním již existujícího znalostního souboru.

Jakmile má kamera svou znalostní základnu, může začít rozpoznávat ryby samostatně, bez připojení k počítači. Umělá neuronová síť je třídí do kategorií přijmout, odmítnout, recyklovat a prázdná přihrádka. Tento signál jde do programovatelného automatu, který řídí dva kartáče, přesouvající příslušné ryby do nádob pro odmítnutí nebo pro recyklaci. Programovatelný automat je napojen také na magnetický senzor, který generuje spouštěcí signál pro pořízení snímku pokaždé, když detekuje přihrádku procházející před kamerou.

Společnost Pisces doposud nainstalovala přes 20 systémů na 5 různých flotilách v Norsku, na Islandu, ve Skotsku a v Dánsku. Tento systém kontroluje u linek na zpracování sledů 360 dopravníkových přihrádek za minutu, ale dokáže pracovat ještě rychleji. Dosahuje 98 % přesnosti při klasifikaci 16 tun ryb pomocí 80 neuronů. Rybáři si jej nemohou vynachválit pro jeho spolehlivost, flexibilitu a snadné používání. K jeho přínosům patří kratší délka expedice, vyšší kvalita

úlovku a možnost rozdělit výnosy mezi menší počet rybářů.

V prostředí diskrétní výroby našly neuronové sítě své uplatnění při kontrolách vozidel, rozpoznávání vzorů u radarových systémů, identifikaci obličejů, rozpoznávání objektů, ručně psaného textu, gest a řeči.

Fuzzy logika se využívá při řízení dílčích systémů automobilů a jiných vozidel, např. u protiblokovacích systémů brzd (ABS), tempomatů, klimatizace, kamer, digitálního zpracování obrazu, umělé inteligence v počítačových hrách a rozpoznávání vzorů u vzdálených senzorových systémů.

Tyto inteligentní systémy (soft computing) se používají také pro výrobu spolehlivé nabíječky baterií pro dýchací přístroj (viz str. XX). V oborech využívajících průběžné a dávkové procesy jsou fuzzy logika a neuronové sítě mozky některých samočinně se nastavujících regulátorů. Některé mikroregulátory a mikroprocesory jsou dokonce optimalizovány pro fuzzy logiku, takže tyto systémy mohou běžet ještě rychleji (viz níže „Rychlá fuzzy logika pro řízení v reálném čase“).

ce

C. G. Masi je vedoucí redaktor časopisu Control Engineering. Kontaktujte jej na adrese charlie.masi@reedbusiness.com.

Rychlá fuzzy logika pro řízení v reálném čase

I když může jakýkoli mikrořadič (MCU) nebo počítač implementovat algoritmy fuzzy logiky v softwaru, u typických MCU nebo počítačů je to poněkud neefektivní – vyžaduje to spoustu programového prostoru a výpočetního času. Jim Sibigtroth, systémový technik pro produkty pro automobily divize mikrořadičů skupiny Transportation and Standard Products Group společnosti Freescale Semiconductors, říká, že firemní mikrořadiče HC12 a HCS12 řeší tento problém doplněním čtyř instrukcí, speciálně navržených pro velice efektivní implementaci hlavních součástí inferenčního nástroje fuzzy logiky.

„Hlavní program pro všeobecný inferenční nástroj fuzzy logiky, který zpracovává nevážená pravidla, zabírá zhruba 57 bajtů objektového kódu (zhruba 24 řádků kódu kompilace),“ říká.

Připomíná, že mikrořadič HCS12, pracující na frekvenci 25 MHz, dokáže vykonat plnou inferenční sekvenci pro systém s dvěma vstupy a jedním výstupem se sedmi značkami pro každý vstup a výstup během zhruba 20 μs. Ekvivalentní program na mikrořadiči MC68HC11, pracujícím na frekvenci 8 MHz (bez instrukcí pro fuzzy logiku), by zabral zhruba 250 bajtů objektového kódu a jeho vykonání by trvalo asi 750 μs. I kdyby mikrořadič MC68HC11 dokázal pracovat na stejné frekvenci jako mikrořadič HCS12, instrukce pro fuzzy logiku stále zajišťují, že program je 4krát menší a 12krát rychlejší. Tyto krátké inferenční časy dovolují používání fuzzy logiky u řídicích aplikací pracujících v reálném čase, bez nákladného výpočetního hardwaru nebo rozsáhlých programů.

Autor: C. G. Masi Control Engineering

<< zpět