

PREDICTION OF GROWTH OF THE AORTIC ANEURYSM USING ARTIFICIAL NEURAL NETWORK

L. Horný*, V. Třeška, J. Vtípil***

Summary: *Abdominal aortic aneurysm is usually manifested like balloon dilation of the distal aorta. This bulge is probably caused by degradation processes in an arterial wall. Sharp cause of this rising of arterial wall is not well known at the present. Mostly is attended by strong atherosclerotic damage of arterial wall. AAA is most often diagnosed below renal arteries. Arterial diameter can overgrow 6 – 7 cm. Adult man mean value of aortal diameter below renal arteries is 2,5 cm. It is seen that growth of aortic abdominal aneurysm can lead to really big values of diameter or to ropture. Presently, there is no reliable criterion to predict the behavior of AAA and the risk of rupture of abdominal aortic aneurysm. Eighty five percents patients with the rupture AAA is dying. So the risk of rupture of AAA is very grave problem. Most common surgical criterion is based on the values of arterial diameter diameter growth rate only. Indicated to surgery are values of diameter over the 5 cm. But this criterion can not include other important factors as for example arterial mechanics, strength of the wall etc. We suppose that our research will be support for the finding of this prediction criterion and will improve surgery indication. Our method is based on using of artificial neuronal networks. Using this one we try to find respopnse to simply question: Will abdominal aortic aneurysm grow or not? Because in clinical medicine are known situations when AAA stoped its growth. (But never decrease). And using this method we can response second question: How much will aortic diameter increase per time unit. We think that this is the way which is more helpful than other one.*

1. Aneuryzma břišní aorty

Nemoci srdečněcévního systému jsou nejčastější příčinou úmrtí ve vyspělých zemích a ne jinak tomu je v České Republice. Jedním ze závažných onemocnění tohoto druhu je aneuryzma břišní aorty (AAA). Aneuryzma (výduť) břišní aorty je definováno jako rozšíření subrenálního úseku aorty o více jak 50% v porovnání s průměrem břišní aorty u zdravé, věkem a pohlavím odpovídající populace. Nejnebezpečnějším jevem doprovázejícím výskyt AAA je v tomto směru ruptura (prasknutí) AAA (RAAA), která může zapříčinit zakrvácení

* Ing. Lukáš Horný, Ing. Jaroslav Vtípil : Laboratoř biomechaniky člověka, Ústav mechaniky, Fakulta strojní, ČVUT v Praze; Technická 4; 166 07 Praha 6; tel.: +420.224 352 527, fax: +420.233 322 482; e-mail: vtipil@biomed.fsfd.cvut.cz

** Prof. MUDr. Vladislav Třeška, DrSc.: Chirurgická klinika Fakultní Nemocnice Plzeň Lochotín; Alej Svobody 80; 323 18 Plzeň

pacienta, jež mnohdy končí smrtí. Výskyt AAA je nejčastější v mužské populaci ve věku kolem 70 let. Ruptura AAA si ročně vyžádá více než 15 000 úmrtí, přičemž RAAA je doprovázena 85% mortalitou. Naneštěstí se výskyt tohoto onemocnění stále zvyšuje a zdá se, že jde o zvýšení skutečné, nikoliv jen v důsledku zlepšujících se diagnostických metod.

Procesy, které vedou ke vzniku aneuryzmatu, jsou ovlivněny mnoha faktory a přesná etiologie všech typů aneuryzmat stále ještě není dokonale známa. Při vzniku AAA hrají zásadní roli především dědičnost, hemodynamické faktory – typ prudění krve, hypertenze, jiná cévní onemocnění – ateroskleróza, záněty cév, různé ischemie etc. Zcela samostatnou kapitolu zde pak tvoří pacienti trpící například Marfanovým syndromem či Erdheimovou chorobou. Přibližně tak můžeme aneuryzmata rozdělit na: aterosklerotická, zánětlivá, mykotická, jiná – vniklá v důsledku degradativního poškození tepenné stěny (Marfanův syndrom). Morfologicky můžeme AAA rozdělit na malá (průměr menší než 5 cm) a velká (průměr nad 5 cm).

V současné době je v kardiovaskulární chirurgii jednoznačnou indikací k chirurgickému řešení AAA (resekci či endovaskulární léčbě) především hodnota maximálního průměru AAA a rychlost růstu. Je-li aneuryzma symptomatické, došlo-li k ruptuře, jde-li o asymptomatické AAA s průměrem větším než 5 cm a jde-li o malé AAA (průměr do 5 cm), kde byl prokázán nárůst průměru rychlostí větší než 0,5 cm/6 měsíců jde o jednoznačnou indikaci k operaci [2]. Relativní indikací k operaci jsou velká asymptomatická aneuryzmata u pacientů postižených těžkou srdeční či ventilační nedostatečností či jinými významnými onemocněními.

V dnešní době je věnována velká pozornost výpočtovým modelům (především založeným na MKP modelování), které mají určit napjatost tepenné stěny postižené AAA. Avšak výpočet napjatosti, jehož výsledky by mohly být vstupem do nějaké podmínky mezního stavu, naráží na velké obtíže – především materiálové a geometrické. Geometrické obtíže jsou dnes překonávány modelováním geometrie úlohy založeným na CT rekonstrukci [9]. Měl-li by takový postup nějakým způsobem zasahovat do rozhodování o léčbě, bylo by nutné u každého pacienta k tomu určeného rekonstruovat individuální geometrii. Určení konstitutivní rovnice a jejích materiálových parametrů je další obtíž. Dostatečným množstvím experimentů lze v tomto jistě dosáhnout věrohodných výsledků, ale opět je tu otázka variability stavu poškození (stavu a rozsahu degradace mechanických vlastností tepenné stěny), který opět bude zcela jistě individuální. Samostatnou kapitolou je pak určení vhodného kritéria mezního stavu, vhodné pevnostní podmínky. Zde existují otázky typu: Vyskytuje se snad při ruptuře tepenné stěny něco jako porušování magistrální trhlinou, jak to známe z kovových materiálů? Sestrojení takového kritéria v dohledné době se nám nezdá pravděpodobné. Tím samozřejmě výzkum na tomto poli nijak neztrácí na užitečnosti. Zdá se nám pouze, že klinická aplikovatelnost výsledků získaných pomocí výpočtového modelování (ať už založeném na MKP či analytických metodách) je omezena.

Z těchto důvodů jsme se orientovali jiným směrem. Cílem našeho snažení je najít metodu, která bude predikovat chování aneuryzmatu břišní aorty. Cílem který jsme si stanovili je, abychom dokázali odpovědět na otázku: Jak se bude aneurysma dále vyvíjet. K tomuto účelu se nám zdá velmi výhodné použít pro predikci chování AAA umělé neuronové sítě (ANN), protože neuronová síť nepostupuje podle klasických výpočetních algoritmů, ale umožňuje učení systému a je schopna pomocí naučených dat odpovídat na otázky, kde není přesně známa fyzikální, chemická... podstata problému. Dokáže tuto neznalost obejít.

2. Umělé neuronové sítě

Umělé neuronové sítě vznikly na popud neurofyziologů a neuroinformatiků jako výsledek snahy simulovat chování lidského mozku. V dnešní době se stávají klíčovými v oboru umělé inteligence. ANN jsou vlastně síťové grafy skládající se z mnoha jednotlivých procesorů (neuronů) vzájemně propojených vazbami. Neuronů v sítích bývají často uspořádány do vrstev (hladin), a to podle propojení a podle svých vlastností.

ANN aplikovaná v této práci je dopředná třívrstvá síť s učícím algoritmem back-propagation. Její činnost lze rozdělit do dvou základních fází, učení a vybavování. Přičemž učení je v podstatě hledání parametrů navržené neuronové sítě tak, aby prováděla příslušnou transformaci. Vybavování je vlastně už konečné užívání naučené ANN jako numerické metody.

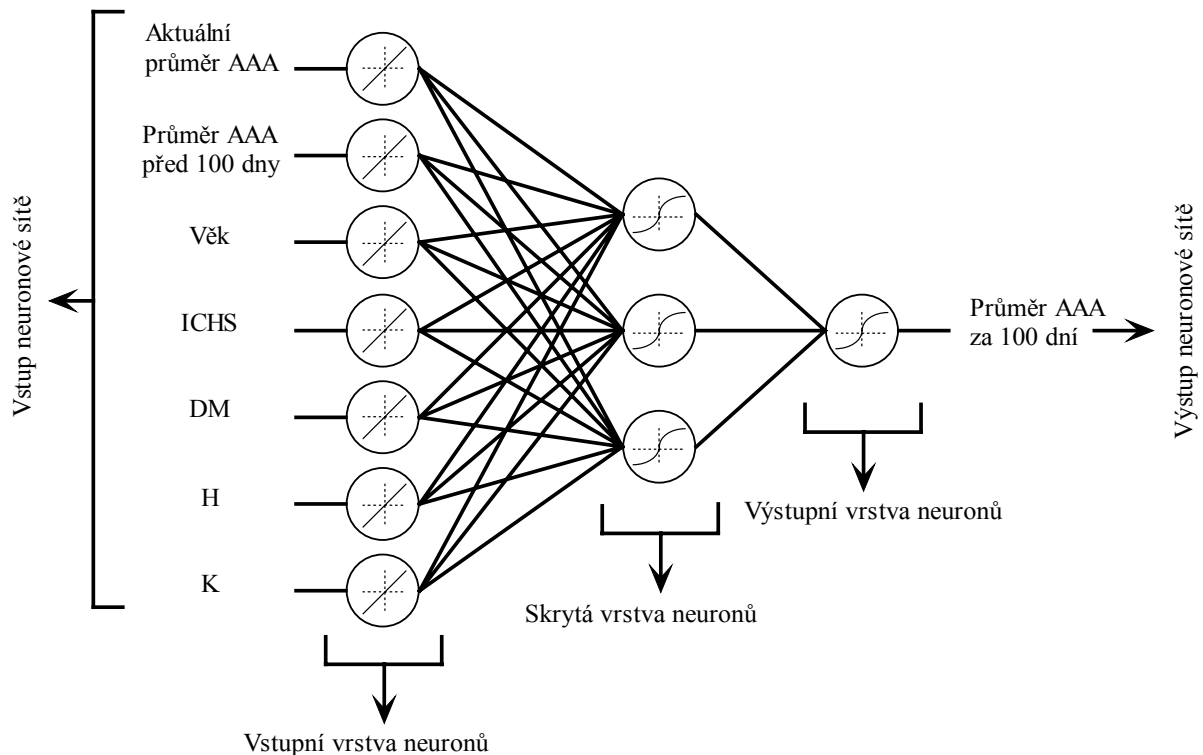
Učení probíhá tak, že na vstup ANN jsou přiváděna vstupní data (vzory) z trénovací množiny (množina vstupů a jim odpovídajících výstupů, jež chceme ANN naučit). Tato data jsou po průchodu neuronovou sítí transformována na výstupní vektor. Ten je porovnán s výstupním vektorem trénovací množiny (žádaným). Chyba (rozdíl mezi těmito vektory) je šířena zpět proti směru sítě a cestou upravuje hodnoty vah a prahů gradientní metodou. Poté je přiložen na vstupní vrstvu další učební vzor a postup se opakuje. Tímto iteračním způsobem se síť učí. Za naučenou je pokládána ve chvíli, kdy rozdíl mezi požadovanou a skutečnou hodnotou výstupního vektoru všech vzorů je minimální.

Vybavování ANN probíhá tak, že na vstup je přiveden vektor, k němuž není znám vektor výstupní. Po průchodu vektoru sítí je získán výstupní vektor, který je jakousi interpolací mezi nejbližšími již naučenými vzory.

3. Metoda

K predikci chování AAA byla jako vhodná vybrána metoda umělých neuronových sítí, která byla popsána výše. Výhoda aplikace této metody spočívá především v tom, že není nutná znalost podstaty a principu sledovaného děje – růstu AAA. Jako podstatná veličina, která bude neuronovou sítí predikována, byl vybrán průměr aneuryzmatu. Důvodem je především to, že právě on – společně s rychlostí svého růstu – slouží v současné cévní chirurgii jako kritérium operativního řešení.

V programu Propagator v1.0 byla vytvořena umělá neuronová síť typu back-propagation s těmito charakteristikami: třívrstvá ANN (jedna skrytá vrstva), 7 vstupních neuronů s lineární přenosovou funkcí, 1 výstupní neuron se sigmoidální přenosovou funkcí, 3 neurony ve skryté vrstvě se sigmoidální přenosovou funkcí, viz *obr. 1*.



Obr. 1: Schema použité neuronové sítě

Vstupními parametry pro učení ANN byly vybrán průměr AAA během posledních dvou měření pacienta (s odstupem asi 100 dní) a dále informace o proměnných o kterých se domníváme, že by mohli chování AAA ovlivňovat. Jsou to: věk, výskyt ischemické choroby srdeční (ICHS), diabetes melitus (DM), hypertenze (H), kouření (K), obstrukční plicní choroba (PP). Informace o ICHS, DM, K, H, PP je vnášena pomocí logické 0 nebo 1. Hodnota průměru aneuryzmatu a věk vystupují v modelu normované od 0 do 1. Z těchto informací je pro každého pacienta utvořen vstupní vektor dat. Výstupem modelu ANN je skalární hodnota průměru aneuryzmatu za 100 dní od provedení posledního měření jež bylo vstupem do ANN.

Vstupní vektory dat byly získány z informací o pacientech postižených malým aneuryzmatem abdominální aorty sledovaných na Chirurgické klinice Fakultní Nemocnice Plzeň – Lochotín. Jedná se o pacienty u nichž byla provedena minimálně tři měření průměru AAA. Celkově byla data získána z 19 pacientů mužského pohlaví. Tato množina pacientů byla rozdělena na množinu učebních pacientů U (z těchto hodnot byla ANN učena) a na množinu testovacích pacientů T (na těchto hodnotách byly testovány výsledky predikce průměru AAA). Jelikož vstupní vektor obsahuje 7 hodnot, bylo by podle našeho názoru zapotřebí ke spolehlivému naučení sítě minimálně řádově 144 kvalitativně odlišných vstupních vektorů. Takový počet měření na tolika pacientech ovšem nebyl k dispozici. Proto byla situace vyřešena následujícím způsobem. Ke všem pacientům byla vytvořena aproximace závislosti normovaného průměru AAA na čase pomocí lineárního splinu. Z každé této aproximace bylo vybráno 7 hodnot a to v časech 0, 100, 200, ..., 600 dní. Výsledek této operace byl dvojitý: 1. došlo k vytěsnění času jako parametru úlohy – všechna data nyní vystupují v rozdílech 100 dní a všechny predikce jsou tak tvořeny na stav následující za 100 dní, 2. došlo k značnému navýšení počtu učebních vektorů úlohy.

Takto navýšený počet vstupních vektorů byl použit k učení sítě a obdobně byly upraveny i testovací hodnoty. Pro práci s ANN byla tedy nakonec množina 88 učebních vzorů (vektorů) a 10 testovacích vzorů. Během učení i testování ANN byl do procesu vnesen uměle náhodný šum s Gausovským rozložením jež representoval chybu měření AAA.

4. Výsledky a závěr

ANN popsaná v předchozí kapitole byla učena zmiňovanou trénovací množinou. Po 50 000 průchodech trénovací množiny neuronovou sítí byla ANN prohlášena za naučenou odpovídala tomu i tzv. energetická chyba ANN. Na vstup naučené ANN byly postupně přivedena zašuměná data všech deseti testovacích vzorů a to pětkrát po sobě. Byla sledována a vyšetřována odchylka průměru AAA predikovaného neuronovou sítí od skutečné (interpolované) hodnoty naměřené na pacientech. ANN v těchto padesáti případech odpovídala se střední odchylkou 0.2 mm a maximální odchylkou 1.5 mm.

Metoda prokázala schopnost predikovat růst AAA na základě několika vstupních parametrů nicméně výzkum nemůže být považován za ukončený. Je nutné rozšířit množinu učebních dat o velké množství případů z klinické praxe. Tímto by bylo možné se vyhnout užití dat využívající, zatím sice nutnou ale poněkud pochybnou interpolaci naměřených dat. Nutno zmínit, že trénovací vzory kvalitativně (ani kvantitativně) nepokrývaly spektrum představitelných případů v dostatečné míře.

Metoda sama má obrovský potenciál pro užití v klinické praxi. Zpětným rozбором parametrů naučené ANN lze navíc identifikovat význam jednotlivých proměnných ovlivňujících vznik a vývoj AAA (jako např. ischemická choroba srdeční (ICHS), diabetes melitus (DM), hypertenze (H), kouření (K), obstrukční plicní choroba (PP), věk). Tyto poznatky by mohly v budoucnu výrazně ovlivnit možnosti léčby a prevence AAA.

Budoucnost projektu tkví v rozšíření učebních dat o větší množství klinických případů, otestování metody přímo na klinickém pracovišti, provedení zpětného rozboru naučené ANN a především přizpůsobení metodiky požadavkům klinické praxe.

Poděkování

Tato práce je podporována výzkumným záměrem MŠ 210000012.

Literatura

Gregor, Z.: Výdutě břišní aorty, www.chirurgie.cz, 1998

Šíma J., Neruda R.: *Teoretické otázky neuronových sítí*. Matfyzpress. 1996

Třeška, V. a kol.: *Aneurysma břišní aorty*, Grada Publishing 1999

Vorp, D. A. – Raghavan, M. L. – Webster, W. M.: *Mechanical Wall Stress in Abdominal Aortic Aneurysm: Influence of Diameter and Asymetry.*, Jour. Vas. Sur., vol. 27, 1998, 632-639

Vtípil – Horný, L.: *Predikce růstu aneuryzmatu břišní aorty pomocí neuronové sítě – výhled*. Summer Workshop of Applied Mechanics. CTU Prague. June 2002. pp. 263-266.