

Možnosti využitia agentového prístupu pri simulovaní ekonomiky

Jaroslav ZAJAC*

Agent – Based Simulation of Economics

Abstract

The work clarifies theoretical bases of the mentioned area learned during the studies of the topic and it analyses existing models, too. It consists of our suggestion of the agent-based model of economy with different types of agents. The created neural networks are used for the agents' decisions.

The result of the work is the implementation of agent-based closed economic simulation model. Negotiation techniques serve to satisfy the parties involved by establishing compromises. We can see the problem of behavioural adaptation of an assembly of agents in two different ways: either as an individual characteristic of the agents – and we then talk of learning – or as a collective process bringing reproductive mechanism into play, which we call evolution.

Key words: multi-agent economy, agent 's relationship, neural networks

JEL Classification: C71, C 72, D62

Úvod

Tento príspevok sa zaoberá agentovým prístupom k simulácii ekonomických modelov. Analyzuje možné prístupy k rozhodovaniu agentov v ekonomickom prostredí, hlavne pomocou aplikácie neurónových sietí a genetických algoritmov. Na rozhodovanie agentov sme použili neurónovú sieť.

Agentové systémy sú založené na vyhľadávaní zovšeobecňujúceho významu v lokálnych interakciách siete jednotlivých členov populácie tak, aby sme dostali celkový význam týchto vzťahov. Tieto modely sa typicky skladajú z prostredia, v ktorom vzájomné interakcie prebiehajú, a z určitého počtu jednotlivcov (teda

* doc. Ing. Jaroslav ZAJAC, CSc., Slovenská technická univerzita, Fakulta elektrotechniky a informatiky, Katedra ekonómie a manažmentu, Ilkovičova 3, 81 209 Bratislava 4; e-mail: jzajac@elf.stuba.sk

agentov). Agent sa väčšinou správa racionálne, avšak s určitou dávkou neistoty. Dôležitou vlastnosťou agenta by mala byť jeho schopnosť učiť sa a prispôbovať okolitému prostrediu. Rozhodovanie je ovplyvnené vonkajšími vplyvmi a vnútorným stavom. Agenti sa ovplyvňujú navzájom a taktiež ich ovplyvňuje prostredie, v ktorom sa nachádzajú. Vlastnosti každého agenta sa sledujú individuálne počas celej simulácie.

Akú charakteristiku by mal teda mať dobrý agentový systém? Odpoveď na túto otázku najlepšie vystihuje jedna z analyzovaných prác [6], a agentový systém, ktorý má tieto vlastnosti:

a) Veľká skupina agentov rôznych druhov. Každý druh agenta má jasne definované správanie (a tým aj svoju úlohu v modeli). Správanie jednotlivých agentov v rámci svojho druhu sa však môže mierne meniť. Zmenu možno dosiahnuť nastavením iných parametrov agenta, prípadne aj implementovaním inej logiky alebo techniky myslenia. Stratégia agenta sa neustále testuje a mení na základe výsledkov interakcií agenta a okolitého prostredia. Inými slovami, správanie agenta sa neustále prispôbuje zmenám v ekonomickom modeli.

b) Dynamické správanie ekonomického modelu ako celku vyplýva zo vzájomných interakcií všetkých agentov (všetkých druhov agentov) v prostredí. To znamená, že celkové výsledky ekonomického modelu vyplývajú zo správania jednotlivých subjektov v modeli.

c) Správanie agenta je odvodené od očakávaní, ktoré má o budúcnosti. To vyžaduje určitým spôsobom vedieť predpovedať budúcnosť ekonomického systému.

Množstvo podnetov, ktoré sa v systéme vyskytuje, a ktoré agent dokáže spracovať, určuje kvalitu agenta. Vstupné informácie agent ďalej spracúva a vyhodnocuje. Na tento účel používa aj svoj vnútorný stav, niečo ako pamäť alebo databázu skúseností. Výstupom agenta je následná akcia do okolitého prostredia.

Spôsoby rozhodovania agenta ako ekonomického subjektu môžeme rozdeliť na niekoľko typov:

- *Náhodné rozhodovanie.* V tomto prípade ide o agentov s nulovou inteligenciou. Pravdaže, agent nekoná úplne chaoticky, správa sa podľa určitých, vopred definovaných pravidiel. Nič sa však neučí a ani nevie nič predvídať. Rozhodovanie prebieha podľa navrhutej pravdepodobnostnej funkcie.

- *Rozhodovanie na základe pamätania si predchádzajúcich stavov.* Agent sa učí na základe vlastných skúseností. Každú udalosť, ktorá sa vyskytne v systéme, si agent uloží do svojej vnútornej pamäte. Pri rozhodovaní agent najprv zistí, či už stav, ktorý má posúdiť, niekedy nastal. Ak áno, svoje rozhodnutie upraví na základe zapamätaných údajov. Ak nie, rozhodne sa zväčša opäť náhodne. Nevýhoda tohto spôsobu je vo veľkosti použitej vnútornej pamäte, ktorá v reálnych podmienkach nemôže byť neobmedzená. Tento spôsob rozhodovania tiež nevie

rýchlo preklenúť prípadné zmeny systému. Agent nemá funkcie na predvídanie a zovšeobecňovanie javov.

• *Rozhodovanie založené na princípe umelej inteligencie.* Myšlienkou tohto prístupu je to, aby sa agent správal ako mysliaca bytosť. Agent sa dokáže správne rozhodnúť aj v tom prípade, ak má niektorý problém predložený prvýkrát. Má schopnosť zovšeobecniť naučené vedomosti a aplikovať ich na nový problém. Je to teda adaptívny systém, ktorý sa prispôsobuje okolitému daniu. Ako konkrétne riešenie tejto problematiky sa v agentových systémoch používajú najmä neurónové siete, genetické algoritmy a evolučné hry. Každá metóda má ešte množstvo rôznych variácií a zväčša je vhodná na riešenie špecifických problémov. V našej práci sme si zvolili riešenie pomocou neurónových sietí. Posudzovali sme aj spôsob využitia genetických algoritmov, pretože je to jeden z ďalších možných riešení tejto problematiky.

1. Neurónové siete

Neurónové siete majú niekoľko možných spôsobov použitia: • znižovanie zložitosti vstupných dát agenta • hľadanie závislostí vo vstupných dátach použiteľných pre proces rozhodovania • zovšeobecňovanie (interpolácia) pre rozhodovanie • predpovedanie vývoja pre rozhodovanie • rozhodovanie agenta na základe hodnôt a časovej postupnosti vstupných dát • kvalifikácia, výber rozhodnutí • asociácia vstup, výstup, použitie ako pamäť.

Použitie genetických algoritmov je v podstate možné všade tam, kde sa dajú použiť neurónové siete. Sú veľmi vhodné na simulácie populácií agentov, ktoré majú životný cyklus, pretože priamo v genetických algoritmoch je zakomponovaný proces vzniku nového jedinca na základe dedičnosti a mutácií.

Umelé neurónové siete (NS) patria medzi adaptívne výpočtové systémy. Majú vlastnosť učenia sa z príkladov, paralelného spracovania a zovšeobecňovania [5]. Zjednodušene povedané, NS sa snažia napodobňovať správanie ľudského mozgu pri spracovaní informácií, klasifikácii vzorov alebo situácií, optimalizačných a predikčných úlohách, rozhodovaní a učení sa. Neurónové siete funguje ako univerzálny aproximátor funkcií.


Základným elementom NS je neurón (obr. 1). Neurón prijíma vstupné signály $\bar{x} = (x_1, x_2, \dots, x_n)$ cez synaptické váhy $\bar{w} = (w_1, w_2, \dots, w_n)$. Výstup neurónu je daný ako

$$y = f(\bar{x} \cdot \bar{w}) = f\left(\sum_j x_j \cdot w_j\right) \quad (1)$$

kde funkcia f sa nazýva aktivačná funkcia neurónu.

Obrázok 1


Model neurónu



Na nasledujúcom obrázku (obr. 2) je znázornená topológia neurónovej siete. Táto NS je viacvrstvová. Neuróny vo vstupnej vrstve dostávajú podnety len z vonkajšieho prostredia. Ich výstupy postupujú na ďalšie spracovanie do skrytej vrstvy. Skrytá vrstva dostáva signály od vstupnej vrstvy a jej výstupy smerujú ďalej do NS. Výstupná vrstva je podobná ako skrytá, s tým rozdielom, že výstupy putujú do externého sveta.

Obrázok 2

Topológia viacvrstvej NS



Takéto rozdelenie vrstiev v NS platí iba v prípade, že ide o neurónovú sieť so šírením signálu vopred (*feed-forward neural network*).

Učenie sa je základnou a podstatnou vlastnosťou neurónových sietí. Všeobecne môžeme učenie sa rozdeliť do dvoch skupín:


• Učenie sa s učiteľom (*supervised learning*) – je známy „učiteľ“ NS, niekto, kto pozná správny výsledok. Pri učení sa NS takýmto spôsobom sa porovnáva výsledok, ktorý dosiahla NS s výsledkom, ktorý „učiteľ“ prehlásil za správny.

• Učenie sa bez učiteľa (*unsupervised learning*) – v tomto spôsobe učenia sa NS nepoznáme správny výsledok. Podľa určitých zákonitostí sa NS hodnotí sama.

Iným typom neurónovej siete, ktorý môžeme potenciálne využiť pri rozhodovaní agenta, sú *rekurentné neurónové siete* (obr. 3). Kým klasická neurónová sieť pracuje viac menej ako *look-up table*,¹ rekurentná neurónová sieť sa snaží zachytiť aj časové závislosti vo vstupných dátach. Výstup NS teda neovplyvňujú len vstupné dáta, ale aj vnútorná informácia o doterajšej histórii vstupných dát. Takáto neurónová sieť sa dá výhodne použiť pri predpovedaní výsledkov a hľadani závislostí v dátach.

Obrázok 3

Bloková schéma rekurentnej neurónovej siete



Navrhnutý agentový systém má nasledovné vlastnosti:

1. V modeli existujú 4 druhy agentov: domácnosti, firmy, banky a štát.
2. Agenti sú navzájom v určitých interakciách. Tieto interakcie predstavujú vzťahy rôznych typov subjektov v reálnom svete. Domácnosti zarábajú peniaze, ukladajú peniaze do bánk a nakupujú aj akcie firiem. Firmy zarábajú a tiež ukladajú peniaze do bánk, ale aj nakupujú akcie iných firiem. Banky peniaze investujú a vyplácajú úroky.
3. Štát plní funkciu prijímateľa poplatkov (daní), ktoré používa väčšinou na sociálne ciele – dotácie domácností, ktoré sú pod úrovňou životného minima, pôžičky bankám pri dočasnej platobnej neschopnosti.
4. Rozhodovanie agentov je implementované pomocou NS, kde každý agent sa rozhoduje na základe vstupných podnetov a svojho vnútorného stavu.

¹ Dvojice vstup – výstup sú napevno priradené.

Základnou požiadavkou je vytvoriť taký model, kde agenti budú reagovať nielen podľa vopred definovaných pravidiel, ale aj podľa naučených, časom získaných skúseností. Schopnosť učenia sa agentov získame pomocou neurónových sietí. Tým dosiahneme aspoň čiastočné priblíženie reálnemu svetu, kde agenti – ekonomické subjekty konajú na základe informácií, ktoré majú o prostredí a na základe získaných skúseností.

Znamená to, že v našom simulačnom prostredí nie je definovaná plocha, na ktorej by boli jednotliví agenti rozmiestnení. Hlavnou úlohou každého agenta je investovať svoj kapitál tak, aby ho zhodnocoval, dosahoval zisk. Simulácia prebieha v cykloch. Každý agent má svoje vnútorné vlastnosti, ktoré charakterizujú jeho správanie. Agenti sa rozhodujú pomocou rozhodovacích funkcií založených na neurónových sieťach. V prípade, že je potrebná určitá „vôľa“ agenta (stochastické správanie), agent sa rozhoduje náhodne.

Agentov môžeme rozdeliť na dve hlavné skupiny – skupinu *aktívnych agentov* a skupinu *pasívnych agentov*. Prvú skupinu tvoria „hráči“. Sú to agenti, ktorí podnikajú – investujú peniaze a mňajú získaný finančný kapitál. Do druhej skupiny patrí štát, pretože v našom modeli sám nevykonáva zárobkovú činnosť. Základnou myšlienkou pri návrhu modelu bolo to, aby sa prvá skupina agentov (teda domácnosti, firmy a banky) odlišovala len v nastavení svojich vnútorných parametrov. Dôvodov na toto rozhodnutie je niekoľko. Okrem jednoduchšej implementácie je to najmä fakt, že všetci agenti sa v podstate správajú rovnako, a preto je vhodné, aby boli navrhnutí ako jednotná štruktúra.


1.1. Podnikanie agenta

Agenti domácnosť, firma a banka podnikajú. Znamená to, že každý z týchto agentov sa snaží zhodnocovať svoj majetok. Zhodnocovanie prebieha tak, že časť finančného majetku agent vyhradí na podnikanie a tieto prostriedky následne investuje. Z tejto investície, samozrejme, očakáva zisk. Treba myslieť aj na to, že výsledky podnikania musia závisieť práve od kvality rozhodnutia agenta (od jeho schopností), a nie iba od náhody.

Aby agenti mohli medzi sebou „zvädzať boj“, to znamená, aby sa dalo určiť, či niektorý agent dosahuje lepšie výsledky ako iný, bolo potrebné vymyslieť úlohu, ktorú budú agenti plniť. Táto úloha predstavuje formu podnikania. Lepšie splnená úloha znamená väčší zisk pre agenta. V rozhodovaní agenta sa tak na riešenie úlohy dajú použiť niektoré prístupy umelej inteligencie. Nečakaná zmena náročnosti úloh môže v simulačnom prostredí charakterizovať zmeny ekonomického prostredia – napríklad technologický šok. Rozhodovanie agenta by sa malo vedieť prispôbiť aj týmto zmenám. Ako úlohu, ktorú bude agent riešiť, sme zvolili jednoduchú hru „háďania čísel“ (obr. 4).

Obrázok 4

Investičná úloha agentov



Majme niekoľko vstupných čísel, povedzme od 0 do 63. Označme si ich x . Ku každému vstupnému číslu x je priradené číslo y z rozsahu $\langle 0,1 \rangle$. Priradenia môžu byť vytvorené náhodne, alebo môžu tvoriť nejakú funkciu, napríklad funkciu sínus. Na úvod, pri trénovaní agenta, agentovi prezradíme niekoľko vstupných hodnôt x (prípadne aj všetky) aj s ich priradenými hodnotami y . Prebieha teda učenie sa, keď si agenti musia zapamätávať uvádzané kombinácie. Neskôr pri podnikaní agenti musia na základe vstupnej hodnoty x správne určiť jej protihodnotu y . Odchýlka od tejto hodnoty znamená kvalitu podnikania agenta. Počiatočným nastavením vstupného rozsahu hodnôt a zmenou zložitosti výstupnej funkcie môžeme ovplyvniť zložitosť celej hry. Ak nečakane zmeníme niektoré hodnoty y , jednoducho tým vnesieme do prostredia šok, s ktorým sa agenti musia vedieť vyrovnávať.

Pravda, ak by rozhodovanie agenta bolo založené len na jednoduchom zapamätávaní priradení $x \rightarrow y$, by mohol dosahovať výborné výsledky. Ťažko by sa však prispôboval šokom. Preto sme navrhli, aby sa agenti v tomto smere rozhodovali pomocou neurónových sietí, ktoré sa na takéto účely často používajú. Agent si na začiatku natrénuje svoju neurónovú sieť na určovanie priradení $x \rightarrow y$. Počas simulácie sa tieto priradenia využívajú na určovanie kvality investovania agenta. Ak sa priradenia zmenia, je úlohou neurónovej siete, aby sa naučila rozpoznávať nové hodnoty. Práve kvalita neurónovej siete určuje kvalitu rozhodovania agenta. Nič však agentovi nebráni v tom, aby na optimalizáciu presnosti svojich rozhodnutí používal aj iné techniky.

Na rozhodovanie sme použili 2-vrstvovú *backprop* sieť [2]. Všetky neuróny majú ako aktivačnú funkciu $f(\text{net})$ použitú unipolárnu sigmoidu. Výstupná vrstva je tvorená jedným neurónom. Navrhujeme, aby počet neurónov skrytej vrstvy mohol určovať používateľ. Vstupom siete je informácia o veľkosti hodnoty x . Spôsob zadávania vstupných hodnôt sa rieši pomocou binárneho zápisu. To znamená, že konkrétne pre 64 vstupných hodnôt je nutné použiť 6 bitov. Neuróny

v skrytej vrstve budú mať teda 6 (+1) vstupov. Výstup neurónovej siete je tvorený jedinou hodnotou s rozsahom 0 až 1. Výstupná hodnota by sa mala približovať k vopred určenému y , tak ako je to opísané v predchádzajúcej časti.

Každý agent má svoju vlastnú neurónovú sieť, samostatne inicializovanú, tréňovanú i používanú. Teraz si stručne popíšme postup fungovania navrhovaného simulátora:

1. Používateľ určí počiatočnú zložitosť investičnej hry. Zvolí teda počet vstupov x (hodnota sa rovná 2^{bitov}) a priradenie príslušných výstupov y .

2. Každému agentovi nastaví jeho neurónovú sieť. Určí počet neurónov skrytej vrstvy, parametre neurónov. Určí aj priebeh výstupných hodnôt, ktoré sa agent musí naučiť, aká maximálna odchýlka sa ešte považuje za správnu hodnotu a koľko tréningových cyklov má maximálne agent k dispozícii.

3. Spustí inicializáciu modelu, pri ktorej prebieha učenie sa neurónovej siete. Agentovi sa predkladajú dvojice x , y a na týchto hodnotách sa agent trénuje. Tréningovanie končí vtedy, keď agent ovláda predpísaný počet kombinácií, alebo ak počet tréningových cyklov prekročí stanovenú hranicu. Obmedzenie počtu tréningových cyklov navrhujeme hlavne z toho dôvodu, že niekedy sa neurón nedokáže naučiť predpísaný počet hodnôt. Tréningovanie agenta sa však musí skončiť v konečnom čase.

4. Agenti podnikajú – investujú kapitál. Simulačné prostredie náhodne vygeneruje jednu hodnotu x a od agentov očakáva, že určia y . Po ohodnotení ich odhadov im prezradí správny výsledok, aby si agenti mohli tréňovať svoje siete aj počas samotného behu programu, a tak sa prispôbovať zmenám v prostredí.

1.2. Funkcie agentov: domácnosť, firma, banka

Ďalší rozdiel medzi jednotlivými agentmi je v predmete ich činnosti. Máme tým na mysli to, ako sa agent správa vo vzťahu k iným agentom:

1. Domácnosti – investujú vlastný kapitál, no neumožňujú, aby iní agenti vkladali svoj kapitál do nich. Znamená to, že domácnosť nepôsobí ako banková, a ani ako nebanková finančná inštitúcia.

2. Firmy – investujú vlastný kapitál, a zároveň sú ochotné zhodnocovať cudzie vklady. Zhodnocovanie cudzích vkladov je však vždy negarantované. Banky – investujú vlastný kapitál, a zároveň prijímajú vklady iných agentov, ktoré zhodnocujú. Garantujú sľúbený výnos. Ak túto garanciu nemôžu splniť pre platobnú neschopnosť, pomocnú ruku im podá štát.

1.3. Štát

Každý aktívny agent, ktorý vyprodukuje nejaký zisk, musí odvieť časť tohto zisku do štátnej pokladnice.

Agent – štát vyzbierané prostriedky používa na dotácie agentov. Každý typ agenta, ktorý podniká, má určenú výšku minimálneho kapitálu, ktorý musí vlastniť. Tento kapitál prirovnávame k životnému minimu a jeho presnú výšku si používateľ môže v modeli sám nastaviť.


Ak sa niektorý aktívny agent dostane pod hranicu životného minima, agent štát mu dodá finančnú výpomoc. Doplní mu stav kapitálu tak, aby bol presne na hranici minima.

1.4. Vzťahy medzi agentmi

Vzťahy medzi agentmi vyplývajú zo služieb, ktoré sami poskytujú. Na obrázku 5 sú tieto vzťahy graficky znázornené.

Obrázok 5

Vzťahy medzi agentmi



1. Domácnosti nemajú interakcie navzájom, ich vklady smerujú do firiem a do bánk. Domácnosti platia dane štátu a od štátu môžu dostávať podporu vo forme dotácií.

2. Firmy vkladajú peniaze aj navzájom medzi sebou, ale aj do bánk. Platia daň štátu a od štátu dostávajú dotácie.

3. Banky môžu vkladať peniaze medzi sebou, alebo ich používajú na nákup akcií firiem. V prípade neschopnosti vyplácať vklady štát za nich relatívne preberá záväzky do určitej výšky.

Všetci agenti majú navyše možnosť investovať kapitál do vlastného podnikania.

2. Vlastnosti agentov

Vlastnosť – pracovitosť určuje ochotu, vôľu agenta v danom simulačnom cykle pracovať. Neurčuje však príležitosť pracovať. Pracovitosť je číslo od 1 do 10. Čím väčšie číslo, tým je pracovitosť agenta väčšia. Táto vlastnosť by sa dala opísať aj pomocou pravdepodobnosti. Väčšie číslo predstavuje väčšia pravdepodobnosť, že agent bude v danom simulačnom cykle pracovať. Rozloženie čísel je navrhnuté tak, aby agent s pracovitosťou 1 nepracoval takmer nikdy, s číslom 10 takmer vždy.

Ochota riskovať určuje najväčšie riziko, ktoré je agent ochotný podstúpiť. Je to opäť číslo v rozsahu 1 až 10. Čím väčšie je číslo, tým agent pri investovaní viac riskuje. Riziko je vlastne ukazovateľ do matice rizika.

Počiatočná veľkosť kapitálu udáva množstvo peňazí, ktoré agent dostáva pri inicializácii modelu na to, aby mal s čím podnikáť. Navrhujeme, aby si toto číslo opäť mohol určiť sám používateľ pre každého agenta osobitne.

Parameter určuje, koľkokrát bude agent hľadať najlepšiu banku a firmu, do ktorej investuje. Vychádzali sme z predpokladu, že ekonomický subjekt sa pri investovaní rozhoduje na základe informácií získaných o konečnom počte možných investícií. Nikdy nemá informácie o všetkých subjektoch na trhu. Preto je jeho rozhodnutie najlepšie iba v rámci úzkej skupiny možností, ktorú preskúmal. Táto hodnota sa dá nastaviť pre každého agenta samostatne.

Hodnota – maximálny hazard plní funkciu obmedzenia výšky vkladov agentov do podnikania. Agent tak môže vložiť iba limitované množstvo peňazí. Navrhujeme, aby tú funkciu mal používateľ možnosti nielen nastaviť, ale aj vypnúť.

Každý agent si pri inicializácii simulácie trénuje neurónovú sieť. Trénovanie neurónovej siete sa končí vo dvoch prípadoch:

1. Ak sa agent naučil rozpoznávať dostatočný počet priradení. Počet priradení, ktoré má agent ovládať, sa určuje v percentách z celkového počtu možností, pre každého agenta samostatne.

2. Ak počet tréningových cyklov dosiahol vopred určený počet (kritické zastavenie).


Nastavovaním oboch prípadov môžeme ovplyvňovať kvalitu natrénovania neurónovej siete a tým vlastne aj kvalitu agenta.

2.1. Rozhodovanie

Rozhodovanie navrhujeme riešiť cez neurónové siete (ktoré v konečnom dôsledku tiež predstavujú algoritmus), no ostáva nám navrhnúť ešte niekoľko procesov, podľa ktorých budú jednotliví agenti postupovať pri svojej činnosti. Na obrázku 6 je znázornený najzákladnejší algoritmus, ktorým sa riadia všetci agenti zo skupiny domácnosť, firma, banka. Je to *algoritmus investovania* agenta, v ktorom stručne načrtávame činnosť agenta pri nakladaní s financiami.

Obrázok 6

Algoritmus investovania agenta



Ako prvé agent určuje, či bude v danom simulačnom cykle pracovať, alebo nie. Ak nebude pracovať, algoritmus sa končí a agent sa dostane k slovu až v ďalšom cykle. Nasleduje rozdelenie vlastného kapitálu na známe 4 skupiny: hotovosť, vklady do bánk, akcie firiem a vlastné podnikanie. Ak sa agent rozhodol vložiť určitú sumu ako vklad do banky, nasleduje výber konkrétnej banky. Ak sa agent rozhodol vložiť financie do firmy, nasleduje výber firmy. Časť peňazí určenú na vlastné podnikanie agent investuje do podnikania.

Z týchto investícií sa potom agentovi vyplatí zisk alebo strata. Ak sú investované peniaze od iných agentov (ak nejaké existujú), aj z týchto peňazí sa agentovi vyplatí zisk.

Záver

V článku uvádzame niekoľko príkladov vykonaných simulácií, na ktorých popisujeme dosiahnuté výsledky. Snažili sme sa popísať niekoľko rôznych typov simulácií tak, aby sme predviedli prácu nielen s vytvoreným prostredím, ale aj výsledky, ktoré môžeme od neho očakávať.

Príklad ukazuje ustálenú simuláciu, na ktorej sme zobrazili správanie modelu bez ovplyvňovania zvonka i bez ovplyvňovania vnútornými šokmi.


Ustálený priebeh simulácie

Príklad sme zvolili tak, aby sme ukázali ustálený vývoj ekonomiky. Na obrázku 7 je znázornený priebeh získaný zo simulačného prostredia. Spodná krivka predstavuje celkový majetok agentov. Ekonomika zaznamenala niekoľko drobných recesií (okolo cyklov 125, 325).

Tieto recesie sa však časom zmenili na rast ekonomiky (cyklus 225, 375) a model sa správa ustálene, rast strieda recesiou. Ustálený vývoj má mierne stúpajúci priebeh, s cyklicky sa opakujúcimi zvlňeniami (obr. 8).


Obrázok 7

Graf priebehu celkového majetku ustálenej simulácie



Obrázok 8

Graf činností agentov



Literatúra

- [1] BASU, N. et al: A Microsimulation Model of the Economy. Aspen: Sandia National Laboratories 1996.
- [2] KVASNIČKA, V. et al: Úvod do teórie neurónových sietí. Bratislava: IRIS 1997.
- [3] McFADZEAN, D. et al: A Computational Laboratory for Evolutionary Trade Networks. [Economic report, No. 53.] Iowa: State University 2000.
- [4] MICHALEWICZ, Z.: Genetic Algorithms + Data Structures = Evolution Programs. New York: Springer-Verlag 1994.
- [5] ORAVEC, M et al: Neurónové siete pre číslicové spracovanie signálov. Bratislava: FABER 1998.
- [6] RIVERO, S.L. et al: Economic Theory, Anticipatory Systems and Artificial Adaptive Agents. Brazilian Electronic Journal of Economics, 1994, zv. 2, č. 2.
- [7] SINČÁK, P. – ANDREJKOVÁ, G.: Neurónové siete inžiniersky prístup. Košice: Technická univerzita 1996.
- [8] TESFATSION, L.: Introduction to the CE Special Issue on Agent-Based Computational Economics. Dordrecht: Kluwer Academic Publishers 2000.
- [9] TRYM: Treasury Macroeconomic (TRYM) Model 2001.
[http://www.treasury.gov.au/publications/TreasuryMacroeconomic\(TRYM\)Model/](http://www.treasury.gov.au/publications/TreasuryMacroeconomic(TRYM)Model/)