

Сузана М. Ђорђевић
Верица Р. Милутиновић
Универзитет у Крагујевцу
Факултет педагошких наука у Јагодина
Катедра за математичко-информатичке науке

УДК 371.26-057.875:004.032.26
Оригинални научни рад
Примљен: 30. септембар 2019.
Прихваћен: 15. новембар 2019.

ПРЕДВИЂАЊЕ ОЦЕНА СТУДЕНАТА КОРИШЋЕЊЕМ ВЕШТАЧКИХ НЕУРОНСКИХ МРЕЖА¹

Апстракт: Циљ овог истраживања је развијање и тестирање модела вештачке неуронске мреже за предвиђање оцена из предмета Основе информатике студената прве године Факултета педагошких наука Универзитета у Крагујевцу, Јагодина. Постоји велики број фактора који могу утицати на оцене студената, као што су пол, смер који су одабрали (учитељ, васпитач у предшколским установама, васпитач у домовима), колонијуми, семинарски радови, провера оспособљености рада у једном апликативном софтверу и присуство настави. За потребе истраживања креиран је модел неуронске мреже базиран на Левенберг–Маркварт алгоритму са пропагацијом грешке уназад и трениран на подацима две генерације студената Факултета педагошких наука у Јагодина. Процена тест података показала је да је модел био у стању да исправно предвиди 90% оцена будућих студената. Разматране су импликације за примену модела у пракси.

Кључне речи: вештачке неуронске мреже, предвиђање оцена, ANN, образовно-васпитни процес, Levenberg–Marquardt, предикциони модел.

УВОД

Тежња човека да предвиди догађаје или исходе догађаја на основу одређених предуслова одувек је постојала. Развојем машинског учења, а посебно вештачких неуронских мрежа, ту тежњу могуће је остварити до

¹Овај рад је резултат пројекта „Подизање дигиталних компетенција учитеља” (ПОДИКОМ), (број 451-02-02702/2018-06), који је реализован на Факултету педагошких наука Универзитета у Крагујевцу, Јагодина а финансирало Министарство просвете, науке и технолошког развоја Републике Србије (2018–2019) и билатералног пројекта „Претпоставке и могућности развијања иновативних модела наставе у функцији остваривања транспарентности универзитетског образовања и подизања конкурентности на домаћем и иностраном тржишту знања”, који су реализовали Факултет педагошких наука Универзитета у Крагујевцу, Јагодина (Србија) и Педагошки факултет Универзитета у Приморском, Копар (Словенија), (2017–2019).

неког степена. Још крајем 19. века појавиле су се прве идеје о вештачким неуронским мрежама, што указује на потребу човека да аутоматизује и убрза процесе учења и предвиђања (Ранковић 2008). Први значајнији помак у развоју неуронских мрежа десио је се 1943. године када су Макалок и Питс предложили систем који функционише користећи механизме нервног система (Макалок, Питс 1943). Правило којим се описује процес учења предложио је Хеб 1949. године (Хеб 1949), а прву неуронску мрежу развио је Розенблат 1958. године и назвао је *перцептрон* (Розенблат 1958). Видров и Хоф су 1960. године предложили нови алгоритам учења који су користили за адаптацију параметара са линеарним активационим функцијама (Видров, Хоф 1960). У данашње време најпопуларнија је процедура учења са пропагацијом грешке уназад која је први пут публикована 1986. године (Румелхарт, Хинтон, Вилијамс 1986).

Архитектура слична човековом мозгу и велики број области у којима се неуронске мреже примењују интензивирали су развој теорија неуронских мрежа и истраживања могућности проширења њихове примене. Предвиђање просечних оцена студената једна је од могућности примене вештачких неуронских мрежа у образовању (Абу Насер и др. 2015).

Када је у питању оцењивање студената разумно је претпоставити да ће се предавачи некада двоумити да ли студенту дати нижу или вишу оцену и коначна одлука често се тешко доноси. Предавач би могао да превазиђе такав проблем ако би имао исходе сличних ситуација у претходним циклусима оцењивања. Међутим, такав систем рада би био неефикасан. Вештачке неуронске мреже нуде боље решење датог проблема. На основу оцена које је предавач дао у претходним испитним роковима, неуронска мрежа може да учи и накнадно исправно предвиди оцене студената који тренутно полажу испит. У овој студији биће истражен модел вештачке неуронске мреже која може да предвиди оцене студената пре него што студенти заврше све обавезе везане за дати испит.

Природно, очекује се да ће оцене студената бити нека врста функције која садржи бројне факторе (аргументе) као што су њихови основни подаци и интелигенција. С друге стране, очигледно је да ће бити прилично тешко наћи математички модел који може адекватно моделирати овај однос оцена и фактора који утичу на закључивање датих оцена. Међутим, један реалан приступ предвиђању оцена студената може бити проучавање података о њиховим општим карактеристикама и предиспитним бодовима.

Уобичајен приступ овој врсти проблема је регресиона анализа у којој се подаци фитују што је боље могуће неком функцијом. Решење би био збир суме производа улаза x_j и тежина w_j и константе θ , тј $y = \sum x_j w_j + \theta$, где $j = 1, \dots, n$ (Петровић, 2011). Главни проблеми овог приступа су сложеност одабране функције, избор константе која ће најбоље обухватити све подат-

ке, као и прилагођавање резултата у случају додатних информација. Стога, вештачка неуронска мрежа, која опонаша рад људског мозга при решавању проблема, представља приступ који би могао боље да реши ову врсту проблема.

Главни циљеви ове студије су одређивање променљивих које утичу на оцене студената, њихово претварање у формат погодан за анализу података и дефинисање адекватног модела неуронске мреже за предвиђање оцена студената.

ПРЕГЛЕД ЛИТЕРАТУРЕ

Потреба да се предвиде одређени исходи постоји у различитим научним областима, па је и литература о предвиђању неуронским мрежама широко заступљена у најразличитијим научним пољима. Прва успешна примена неуронских мрежа забележена је у моделирањима и предвиђањима нелинеарних временских низова (Лапедес, Фарбер 1987). Како се нелинеарни временски низови најчешће изучавају у инжењерству и физици, многи аутори из области физике бавили су се предвиђањем помоћу вештачких неуронских мрежа (Лоу, Веб 1990; Дечиш, Бауер, Гизел 1991).

Вештачке неуронске мреже вероватно највећу примену имају у области финансија. Користе се за предвиђање банкротства и пословних губитака (Вилсон, Шарда 1992), кретања страних валута (Вајгенд, Хуберман, Румелхарт 1992), цене акција на берзи (Грудници, Озборн 1993).

ПРИМЕНА НЕУРОНСКИХ МРЕЖА ЗА ПРЕДВИЂАЊА У ОБРАЗОВАЊУ

Када су едукација и образовање у питању, вештачке неуронске мреже најчешће се примењују у предвиђању просечних оцена или коначних оцена у оквиру једног курса или предмета. Многи подаци из школа, универзитета и курсева на даљину коришћени су са циљем да се предвиде успеси ученика. Неуронске мреже коришћене су у предвиђању постигнућа из математике, спеловања и науке петнаестогодишњих ученика на основу њихових породичних података, социјалних и економских статуса (Јунеман, Лагос, Ариагада 2017). Абу Насер и сарадници (2015) користили су неуронску мрежу како би предвидели укупне перформансе студената друге године. Поред демографских карактеристика (пол и година рођења), коришћени су и подаци о средњој школи и битнијим предметима на самом факултету како би се процениле коначне просечне оцене студената. Ливиерис, Дракопулу и Пинтелас (2012) предвиђали су који ће студенти положити испит из ма-

тематике. Податке о ученицима добијене током реализације образовања на даљину користили су Калес и Пиеракеас (2006), као и Коциантис, Пиеракас и Пинтелас (2004) за предвиђање успеха или неуспеха на завршним испитима. Они су користили више техника, укључујући и неуронске мреже, а подаци су обухватили демографске карактеристике, оцене домаћих задатака и присуство настави, тј. пленарним часовима.

Наведене студије односиле су се на различите врсте образовања, као што су класично и образовање на даљину. Оне се, међутим, нису фокусирале на коначне оцене студената у оквиру појединачних курсева (предмета). Са друге стране, предложена метода предвиђања се лако може интегрисати у систем оцењивања, те олакшати посао професорима.

ВЕШТАЧКЕ НЕУРОНСКЕ МРЕЖЕ

Вештачка неуронска мрежа (енгл. *Artificial Neural Network – ANN*) је аритметички модел који је настао по угледу на биолошку неуронску мрежу. Неуронска мрежа садржи међусобно повезани скуп вештачких неурона и она обрађује информације помоћу конективистичког облика за рачунање. Међутим, модели вештачких неурона и вештачких неуронских мрежа су по сложености и организацији далеко иза неурона и неуронских мрежа које постоје у људском мозгу. Дакле, вештачка неуронска мрежа је адаптивни систем који прилагођава своју структуру на основу спољних или унутрашњих информација које теку кроз мрежу током процеса учења. У последње време неуронске мреже су нелинеарни алати за моделирање нумеричких података. Обично се користе за моделирање замршених односа између улаза и излаза или за откривање образаца у подацима.

Вештачка неуронска мрежа се формира од већег броја међусобно повезаних неурона распоређених по слојевима (Ранковић 2008). Слојеви су групе неурона које извршавају сличну функцију. Међусобно су повезани и излази једног слоја чине улазе следећег слоја. Слојеви се могу класификовати у три врсте: улазне, скривене и излазне (Рохас, Фелдман 1966). Улазни слој (енгл. *input layer*) јесте слој неурона који прима информацију од кори-сника. Излазни слој (енгл. *output layer*) шаље информације кориснику. Скривени слој (енгл. *hidden layer*) се налази између улазног и излазног слоја и има произвољан број подслојева, у зависности од комплексности дате мреже. Скривени слој је опциони, док су улазни и излазни слојеви обавезни, мада је могуће да један слој обавља функцију и улазног и излазног слоја (Мартин, Хауард 2014).

Према Ранковићу (2008), у реализованим неуронским мрежама, на деловање средине, најчешће је деловање променом појачања по синапсама,

тј. везама између неурона. Правила за те промене називају се процедурама учења. Учење може бити офлајн (енгл. *off-line*) и онлајн (енгл. *on-line*). Када је у питању офлајн или лабораторијско учење, мрежа се обучава ван средине у којој ће радити, а средина се симулира скупом података за учење где је сваки узорак представљен паром улаз – жељени излаз. Код онлајн учења мрежа се ставља у експлоатацију и учење се обавља на основу података који се добијају из радног окружења (Ранковић 2008).

Кејнејл и Читнис (2011) говоре о обуци неуронске мреже као о процесу помоћу кога су тежинске везе додељене. Већина алгоритама за тренирање започиње додељивањем случајних бројева матрици тежине. Затим се испитује ваљаност неуронске мреже. Следећи корак је прилагођавање тежина на основу тачности учинка неуронске мреже. Овај поступак се понавља све док грешка потврде не буде у прихватљивој граници (Кејнејл, Читнис 2011).

Валидација система врши се након што се неуронска мрежа оспособи и мора се проценити да ли је спреман за стварну употребу. Овај последњи корак је важан како би се могло утврдити да ли је потребна додатна обука. Да би се исправно оценила неуронска мрежа, валидациони подаци се морају потпуно одвојити од података за тренинг.

Подаци за тренирање, тестирање и валидацију мреже се добијају тако што се база података подели на скуп за тренирање, скуп за тестирање и скуп за валидацију. Однос тренинга, теста и валидације у оквиру базе може се узети произвољно, мада се најчешће узима у односу 60%, 30% и 10% (Ранковић 2008).

МЕТОДОЛОГИЈА

ЦИЉ ИСТРАЖИВАЊА

Циљ ове студије је да предвиди оцене ученика на основу неких њихових особина и радова, како би се предавачима олакшало одређивање коначне оцене. Наведеним разматрањем литературе и проучавањем људских експертиза из области оцена ученика издвојили смо низ фактора који могу утицати на учинак у области информатике. Проучавањем ових фактора издвојени су само они који би могли утицати на оцене студената из предмета Основе информатике и синхронизовани су у погодан облик за коришћење у оквиру моделирања неуронских мрежа. Ови фактори су класификовани као улазне променљиве. Излазне променљиве су оцене, тј. бодови које студент сакупи на крају семестра у оквиру предмета Основе информатике.

ХИПОТЕЗЕ ИСТРАЖИВАЊА

На основу резултата досадашњих истраживања у образовању (Абу Насер и др. 2015; Јунеман, Лагос, Ариагада 2017; Ливиерис, Дракопулу, Пинтелас 2012; Калес, Пиеракеас 2006; Коциантис, Пиеракас, Пинтелас 2004), формулисана је следећа хипотеза истраживања: Неуронска мрежа развијена на основу фактора пол, смер студија, резултати два колоквијума, израда семинарског рада, провера оспособљености рада у једном апликативном софтверу и присуство настави, предвидеће коначну оцену студена-та са тачношћу од преко 70%.

УЗОРАК

За потребе истраживања искоришћени су подаци 354 студента који су слушали и полагали Основе информатике у току школске 2017/2018. и 2018/2019. године на Факултету педагошких наука Универзитета у Крагујев-цу, Јагодина. Узорак су чинили подаци студената са свих смерова и то 140 будућих учитеља, 167 васпитача у предшколским установама и 47 васпитача у домовима. Око 60% података (213 студената) искоришћено је за тренирање мреже, око 30% (106) за тестирање и преосталих 10% (35) за валидацију мреже.

УЛАЗНЕ ПРОМЕНЉИВЕ

За улазне променљиве узети су основни подаци о студентима, као и неки од кључних задатака које су студенти остварили у току слушања предмета.

1. Пол
2. Смер студија
3. Резултати постигнути на два колоквијума
4. Израда семинарског рада
5. Провера оспособљености рада у једном апликативном софтверу
6. Присуство настави

Табела 1. Преглед улазних променљивих

Улазна променљива	Домен
Пол	мушки, женски (0,1)
Смер студија	Учитељ, Васпитач у предшколским установама, Васпитач у домовима (1, 2, 3)
Резултати постигнути на два колоквијума	Збир бодова са оба колоквијума (0–40)
Израда семинарског рада	Број освојених бодова на обавезном семинарском раду (0–5)
Провера способности рада у једном апликативном софтверу	Број бодова освојених на обавезној одбрани рада у апликативном софтверу (нпр. Word) (0–12)
Присутство настави	Колико су укупно недеља студенти присуствовали настави од предвиђених 15 недеља (0–15)

ИЗЛАЗНЕ ПРОМЕЉИВЕ

Излазне промељиве представљају оцене студената. Базиране су на тренутном систему оцењивања на Универзитету у Крагујевцу.

Табела 2. Преглед излазних променљивих

Излазне променљиве	Домен (у бодовима)
10 (десет)	Од 91 до 100
9 (девет)	Од 81 до 90
8 (осам)	Од 71 до 80
7 (седам)	Од 61 до 70
6 (шест)	Од 51 до 60
5 (пет)	Испод 50


ДИЗАЈН НЕУРОНСКЕ МРЕЖЕ ЗА ИСТРАЖИВАЊЕ

За предвиђање оцена студената коришћена је двослојна неуронска мрежа са директним простирањем сигнала (енгл. *feedforward neural networks*), са сигмоидалном активационом функцијом у скривеном слоју са 52 неурона и линеарном активационом функцијом у излазном слоју. Мрежа је тренирана Левенберг–Маркварт алгоритмом (*Levenberg–Marquardt*

algorithm – LMA) са пропацијом грешке уназад. LMA алгоритам је најчешће коришћени алгоритам јер се сматра најбржим и напредним алгоритмом за нелинеарну оптимизацију (Маркварт 1963). Познат је још и под називом *метода пригушених најмањих квадрата* (енгл. *damped last squares*). Недостатак алгоритма је у томе што захтева пуно меморије.

У овој студији коришћена је неуронска мрежа са директним простирањем сигнала и пропацијом грешке уназад, која пружа могућност за имплементацију и тестирање неуронске мреже и њеног алгоритма учења. Мрежа је састављена из једног улазног слоја (10 улаза), скривеног слоја (52 улаза) и једног излазног слоја (6 излаза). За имплементацију мреже коришћена је MATLAB 2013b платформа.

Слика 1. Архитектура неуронске мреже



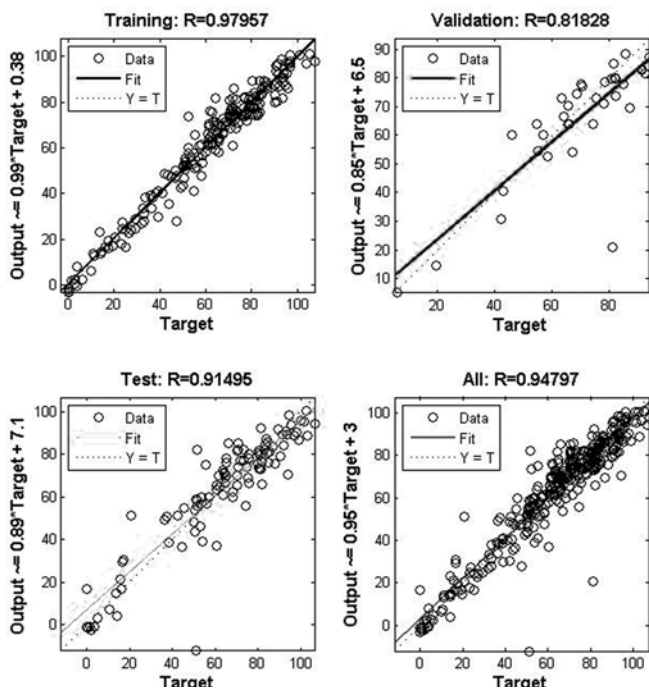
ЕВАЛУАЦИЈА НЕУРОНСКЕ МРЕЖЕ И ДИСКУСИЈА

Као што је већ речено, ово истраживање има за циљ да предвиди коначне оцене студената на предмету Основе информатике на Факултету педагошких наука Универзитета у Крагујевцу коришћењем неуронске мреже формиране на основу следећих фактора: пол, смер студија, резултати два колоквијума, израда семинарског рада, практична одбрана једног апликативног софтвера и присуство настави.

Након обуке и валидације, мрежа је тестирана подацима из тест скупа, што значи да је мрежа добила улазне податке, али не и излазне податке. Мрежа је потом дала своје излазне резултате који су упоређени са излазним подацима базе.

Поређење предвиђених са реалним излазима може се приказати коефицијентом корелације (R). Резултати су показали да је коефицијент корелације за тренинг био 0,98, за валидацију 0,82, а за тест 0,91. Коефицијент корелације за свеукупне перформансе мреже био је 0,95 (Слика 2).

Слика 2. Перформансе неуронске мреже



Ако се на основу датог коефицијента корелације израчуна тачност мреже, добија се налаз да ће мрежа тачно предвидети 90% оцена студената.

На основу коефицијента корелације за укупне перформансе неуронске мреже, закључак је да ће неуронска мрежа на основу постављених улазних параметара предвидети оцене студената са прецизношћу од преко 70%, чиме је потврђена главна хипотеза истраживања.

Ови резултати у складу су са истраживањима Абу Насера и сарадника (2015) јер се показало да пол утиче на побољшање рада неуронске мреже. Резултати колоквијума и присуство настави такође утичу на побољшање перформанси неуронске мреже, како су показали и Ливииерис, Дракопулу и Пинтелас (2012). Израда семинарског рада и провера оспособљености рада у једном апликативном софтверу представљају неку врсту тестирања јер се на тај начин проверава мотивација студената, њихов приступ учењу и

способност меморисања садржаја на часу. Од мотивације студента зависи да ли ће и колико квалитетно урадити семинарски рад. Квалитет семинарског рада такође зависи и од приступа учењу, јер студенти са позитивнијим приступима учењу често имају квалитетније семинарске радове. Способност меморисања садржаја на часу може се показати при провери оспособљености рада у једном апликативном софтверу, јер студенти добијају задатке који су слични онима који се раде на вежбама. Уколико су студенти боље упамтили вежбе са часова, лакше и брже ће урадити проверу са бољим резултатима, што је у складу са налазима Кинта и сарадника (2011).

Формирана неуронска мрежа показала се као ефикасан и брз алгоритам за предвиђање оцена студената са великом тачношћу. У поређењу са другим методама предвиђања, попут линеарне регресије (Хуанг, Фанг 2010; Гадави, Пател 2011), неуронска мрежа се показала као ефикаснија. При том, она генерише функције предвиђања аутоматски, што омогућава брже испитивање већег броја модела у сврху проналажења модела са највећом тачношћу.

ЗАКЉУЧАК

У овом истраживању је коришћена неуронска мрежа са директним простирањем сигнала како би се предвиделе оцене студената у оквиру предмета Основе информатике. Подаци су сакупљени на основу студентских архива на Факултету педагошких наука Универзитета у Крагујевцу. Модел је тестиран и свеукупни резултати су показали 90% тачности у предвиђању коначне оцене.

На основу свега показаног може се уочити потенцијал вештачких неуронских мрежа. У ближој будућности наставници би могли помоћу вештачких неуронских мрежа предвидети оцене ученика на основу њихових почетних резултата. То би им омогућило да ученике лакше поделе у групе за потребе сарадничког рада и да лакше додељују индивидуалне задатке. Такође, недоумице у вези са коначном оценом биле би отклоњене и оцена би била објективнија јер би мрежа приказивала оцену која би могла послужити као предлог наставнику.

Вештачка неуронска мрежа, иако створена по моделу људског мозга, још увек по сложености и организацији заостаје за његовом организацијом. Стога на вештачку неуронску мрежу треба гледати као на саветника у наставном процесу, а не као на самосталну јединицу која може заменити наставника. Ограничења овако формиране неуронске мреже могу се пронаћи у самој бази података на основу које би требало да мрежа учи. Будући да базу чине подаци о оценама које је професор давао студентима током претходних

школских година, мрежа гради критеријуме на основу већ датих оцена. Ова мрежа, дакле, не би могла предвидети оцене без претходних резултата, што би представљало проблем код предмета који се тек уводе као нови.

Будућа истраживања могла би се бавити упоређивањем различитих типова неуронских мрежа у предвиђању оцена студената, као и у одређивању оних са бољим перформансама. Такође, било би добро разматрати и разноврсне друге факторе јер неће сваки предмет имати исте чиниоце који утичу на постигнућа, тј. оцену студента. Из тог разлога, будућа истраживања могла би се бавити испитивањем перформансе неуронских мрежа на другим предметима, са факторима карактеристичним за те предмете. Такође, било би корисно упоредити постигнућа студената на предметима истих научних области..

ЛИТЕРАТУРА

Абу Насер, Закоут, Абу Гош, Аталах, Алајрами (2015): Samy Abu Naser, Ihab Zaqout, Mahmoud Abu Ghosh, Rasha Atallah, Eman Alajrami, Predicting Student Performance Using Artificial Neural Network: in the Faculty of Engineering and Information Technology, *International Journal of Hybrid Information Technology*, 8(2), 221–228.

Вајгенд, Хуберман, Румелхарт (1992): Andreas Weigend, Bernardo Huberman, David Rumelhart, Predicting sunspots and exchange rates with connectionist networks, *Nonlinear Modeling and Forecasting*, Redwood City: Addison-Wesley, 395–432.

Видров, Хоф (1960): Bernard Widrow, Ted Hoff, Adaptive Switching Circuits, *IRE WESCON Convention Record*, 4, 96–104.

Вилсон, Шарда (1994): Rick Wilson, Ramesh Sharda, Bankruptcy Prediction Using Neural Networks, *Decision Support Systems*, 11, 545–557.

Гадави, Пател (2011): Mahesh Gadhavi, Chirag Patel, Student final grade prediction based on linear regression, *Indian Journal of Computer Science and Engineering (IJCSE)*, 8(3), 274–279.

Грудници, Озборн (1993): Gary Grudnitski, Larry Osburn, Forecasting S&P and gold futures prices: An application of neural networks, *Journal of Futures Markets*, 13(6), 631–643.

Депиш, Бауер, Гизел (1991): Josef Deppisch, Hans Ulrich Bauer, Theo Geisel, Hierarchical training of neural networks and prediction of chaotic time series, *Physics Letters A*, 158(1–2), 57–62.

Јунеман, Лагос, Ариагада (2017): María Angélica Pinninghoff Junemann, Pedro Antonio Salcedo Lagos, Ricardo Contreras Arriagada, Neural Networks to Predict Schooling Failure/Success, *Nature Inspired Problem-Solving Methods in Knowledge Engineering*, 571–579.

Калес, Пиеракеас (2006): Dimitris Kalles, Christos Pierrakeas, Analyzing student performance in distance learning with genetic algorithms and decision trees, *Applied Artificial Intelligence*, 20(8), 655–674.

Кејнејл, Читнис (2011): Prakash Khanale, Chitnis, Handwritten Devanagari Character Recognition using Artificial Neural Network, *Journal of Artificial Intelligence*, 4(1), 55–62.

Кент, Мусо, Каселар, Доши (2011): Eva Kyndt, Mariel Musso, Eduardo Cascal-lar, Filip Dochy, Predicting academic performance in higher education: Role of cognitive, learning and motivation, *Earli Conference 2011 edition: 14th*, 30 August – 3 September 2011, Exeter, UK.

Коциантис, Пиеракас, Пинтелас (2004): Sotiris Kotsiantis, Christos Pierrakeas, Panagiotis Pintelas, Predicting Students' Performance in Distance Learning Using Machine Learning Techniques, *Applied Artificial Intelligence*, 18(5), 411–426.

Лапедес, Фарбер (1987): Alan Lapedes, Rob Farber, *Nonlinear signal processing using neural networks: Prediction and system modelling*, Los Alamos: Los Alamos National Laboratory.

Ливиерис, Дракопулу, Пинтелас (2012): Ioannis Livieris, Konstantina Drako-poulou, Panagiotis Pintelas, Predicting students' performance using artificial neural networks, *8th Pan-Hellenic Conference with International Participation Information and Communication Techno-logies in Education*, 321–328.

Лоу, Веб (1990): David Lowe, Andrew Webb, Time series prediction by networks: A dynamical systems perspective, *IEE proceedings. Part F. Radar and signal processing*, 138 (1), 17–24.

Макалок, Питс (1943): Warren McCulloch, Walter Pitts, A logical calculus of the ideas immanent in nervous activity, *Mathematical biophysics*, 5, 115–133.

Маркварт (1963): Donald Marquardt, An algorithm for least-squares estimation of nonlinear parameters, *Journal of the Society for Industrial and Applied Mathematics*, 11, 431–441.

Мартин, Хауард (2014): Hagan Martin, Demuth Howard, *Neural Network Design*, Oklahoma: Martin Hagan.

Петровић (2011): Љиљана Петровић, *Теорија веровајноћа*, Београд: Центар за издавачку делатност Економског факултета у Београду.

Ранковић (2008): Весна Ранковић, *Интелигентно управљање*, Крагујевац: Машински факултет.

Розенблат (1958): Frank Rosenblatt, The perceptron: A probabilistic model for information storage and organization in the brain, *Psychological Review*, 65(6), 386–408.

Рохас, Фелдман (1966): Raul Rojas, Jerry Feldman, *Neural Networks: A Systematic Introduction*, Berlin: Springer.

Румелхарт, Хинтон, Вилијамс (1986): David Rumelhart, Geoffrey Hinton, Ronald Williams, Learning representations by back-propagating errors, *Nature*, 323, 9.

Хеб (1949): Donald Hebb, *The Organization of Behavior: A Neuropsychological Theory*, Oxford, England: Wiley.

Хуанг, Фенг (2010): Shaobo Huang, Ning Fang, Prediction of student academic perfor-mance in an engineering dynamics course: Development and validation of mul-tivariate regression models, *International Journal of Engineering Education*, 26(4), 1008–1017.

Suzana M. Đorđević

University of Kragujevac
Faculty of Education in Jagodina

Verica R. Milutinović

University of Kragujevac
Faculty of Education in Jagodina

PREDICTING STUDENTS' PERFORMANCES USING ARTIFICIAL NEURAL NETWORKS

Summary: The aim of this research is to develop and test an artificial neural network model for predicting first year students' grades in Basics of ICT at the Faculty of Education, University of Kragujevac, Jagodina. A number of factors could influence students' grades, such as gender, study programme students are enrolled in (Class teachers, Preschool teachers, Boarding school teachers), tests, seminar papers, proficiency testing in one application software and class attendance. For the purpose of this research the model based on the Levenberg–Marquardt algorithm with the backpropagation was created and trained on the data of the two generations of students at the Faculty of Education in Jagodina, University of Kragujevac. Assessment of the test data has shown that the model was able to correctly predict 90% of future students' grades. Implications for the application of the model in practice are discussed as well.

Keywords: Artificial neural network, Grade prediction, ANN, Education, Levenberg–Marquardt, Prediction model.