

## UČNI NAČRT PREDMETA/COURSE SYLLABUS

<b>Predmet:</b>	NEVRONSKE MREŽE
<b>Course title:</b>	NEURAL NETWORKS

<b>Študijski programi in stopnja</b>	<b>Študijska smer</b>	<b>Letnik</b>	<b>Semestri</b>
Strojništvo, tretja stopnja, doktorski	Ni členitve (študijski program)		Celoletni

Univerzitetna koda predmeta/University course code:

Predavanja	Seminar	Vaje	Klinične vaje	Druge oblike študija	Samostojno delo	ECTS
90					160	10

**Nosilec predmeta/Lecturer:**

<b>Izvajalci predavanj:</b>	Edvard Govekar, Primož Potočnik
<b>Izvajalci seminarjev:</b>	
<b>Izvajalci vaj:</b>	
<b>Izvajalci kliničnih vaj:</b>	
<b>Izvajalci drugih oblik:</b>	
<b>Izvajalci praktičnega usposabljanja:</b>	

**Vrsta predmeta/Course type:**

<b>Jeziki/Languages:</b>	<b>Predavanja/Lectures:</b>	Slovenščina, Angleščina
	<b>Vaje/Tutorial:</b>	Slovenščina, Angleščina

<b>Pogoji za vključitev v delo oz. za opravljanje študijskih obveznosti:</b>	<b>Prerequisites:</b>
Veljajo splošni pogoji za doktorski študij.	General prerequisites for the third level studies.

<b>Vsebina:</b>	<b>Content (Syllabus outline):</b>
<p>(i) Splošna predstavitev Kaj je nevronska mreža, biološke nevronske mreže, umetne nevronske mreže, prednosti nevronskih mrež, kratka zgodovina nevronskih mrež, uporaba nevronskih mrež</p> <p>(ii) Model nevrona, arhitekture mrež in učenje Model nevrona, aktivacijske funkcije, arhitekture mrež, učni algoritmi, paradigme učenja, učne naloge, predstavitev znanja, nevronske mreže napram statističnim metodam</p> <p>(iii) Perceptroni in linearni filtri Perceptron nevron, perceptronsko učno pravilo, ADALINE, LMS učno pravilo, adaptivni filtri, XOR problem</p> <p>(iv) Vzratno učenje (backpropagation) Večnivojske mreže, algoritem vzratnega učenja, uporaba vzratnega učenja, napredni algoritmi, zmogljivosti večnivojskih perceptronov</p> <p>(v) Dinamične mreže Zgodovinske dinamične mreže, nevronska mreža s</p>	<p>(i) General Introduction What is a neural network?, Biological neural networks, Human nervous system, Artificial neural networks, Benefits of neural networks, Brief history of neural networks, Applications of neural networks</p> <p>(ii) Neuron Model, Network Architectures and Learning Neuron model, Activation functions, Network architectures, Learning algorithms, Learning paradigms, Learning tasks, Knowledge representation, Neural networks vs. statistical methods</p> <p>(iii) Perceptrons and Linear Filters Perceptron neuron, Perceptron learning rule, Adaline, LMS learning rule, Adaptive filtering, XOR problem</p> <p>(iv) Backpropagation Multilayer feedforward networks, Backpropagation algorithm, Working with backpropagation, Advanced algorithms, Performance of multilayer perceptrons</p> <p>(v) Dynamic Networks Historical dynamic networks, Focused time-delay neural</p>

<p>fokusirano časovno zakasnitvijo, nevronska mreža s porazdeljeno časovno zakasnitvijo, NARX mreža, mreža s povratnimi plastmi, zmogljivosti dinamičnih nevronske mreže, učni algoritmi, identifikacija sistemov, modelno referenčno adaptivno vodenje</p> <p>(vi) Mreže radialnih baznih funkcij (RBFN) struktura RBFN mrež, natančna interpolacija, radialne bazne funkcije, mreža radialnih baznih funkcij, RBFN učenje, RBFN za razpoznavanje vzorcev, primerjava z večnivojskim perceptronom, verjetnostne nevronske mreže (PNN), posplošene regresijske mreže (GRNN)</p> <p>(vii) Samo-organizirajoče se mreže Samo-organizacija, samo-organizirajoče se preslikave (SOM), SOM algoritem, lastnosti SOM mreže, učenje z vektorsko kvantizacijo (LVQ)</p> <p>(viii) Praktični napotki Priprava podatkov, izbira vhodov, kodiranje podatkov, metoda glavnih osi (PCA), invariance in predhodno znanje, posploševanje, splošna načela za izgradnjo nevronske mreže</p> <p>(ix) Napredne vsebine Optimalna zgradba mreže, evolucija nevronske mreže, mreže podpornih vektorjev (SVM), committee stroji, naključnostni stroji, mreže glavnih osi</p>	<p>network, Distributed time-delay neural network, NARX network, Layer recurrent network, Computational power of dynamic networks, Learning algorithms, System identification, Model reference adaptive control</p> <p>(vi) Radial Basis Function Networks RBFN structure, Exact interpolation, Radial basis functions, Radial basis function networks, RBFN training, RBFN for pattern recognition, Comparison with multilayer perceptron, Probabilistic networks, Generalized regression networks</p> <p>(vii) Self-organizing maps Self-organization, Self-organizing maps, SOM algorithm, Properties of the feature map, Learning vector quantization</p> <p>(viii) Practical Considerations Preparing data, Selection of inputs, Data encoding, Principal component analysis, Invariances and prior knowledge, Generalization, General guidelines</p>
--	--

#### Temeljna literatura in viri/Readings:

[1] S. Haykin: Neural Networks: A Comprehensive Foundation, 2/E, Prentice Hall, 1999.  
[2] C.M. Bishop: Neural Networks for Pattern Recognition, Oxford University Press, 1995.  
[3] I. Grabec, W. Sachse: Synergetics of measurement, prediction and control, Berlin; Heidelberg; New York: Springer, 1997.  
[4] W. Sarle: Neural FAQ, <ftp://ftp.sas.com/pub/neural/FAQ.html>, 2002.  
[5] MATLAB Neural Networks Toolbox (User's Guide), <http://www.mathworks.com/access/helpdesk/help/toolbox/nnet/>

#### Cilji in kompetence:

**Cilji:**

- (i) predstaviti principe in metode nevronske mreže,
- (ii) predstaviti poglobitvene modele nevronske mreže,
- (iii) prikazati postopek uporabe nevronske mreže v praksi.

**Kompetence:**

Študent bo:

- (i) pridobil razumevanje koncepta nelinearnega modeliranja z nevronske mreže,
- (ii) znal razložiti poglobitvene arhitekture nevronske mreže (večnivojski perceptron, dinamične nevronske mreže, mreže radialnih baznih funkcij, samo-organizirajoče se mreže),
- (iii) razvil sposobnost izgradnje nevronske mreže za reševanje realnih problemov,
- (iv) zmožen zasnovati ustrezno arhitekturo nevronske mreže, doseči dobre učne in posplošitvene rezultate, ter izdelati rešitev z nevronske mreže.

#### Objectives and competences:

**Goals:**

The objectives of the course are:

- (i) to introduce the principles and methods of neural networks,
- (ii) to present the principal neural network models,
- (iii) to demonstrate the process of applying neural networks in practice.

**Competences:**

The student will:

- (i) understand the concept of nonparametric modelling by neural networks,
- (ii) explain the most common NN architectures (multilayer perceptrons, dynamic networks, radial basis function networks, self-organized networks),
- (iii) develop the ability to construct neural networks for solving real-world problems,
- (iv) be able to design proper NN architecture, achieve good training and generalization performance, and finally, implement a neural network solution.

#### Predvideni študijski rezultati:

#### Intended learning outcomes:

<p>Študent bo:</p> <ul style="list-style-type: none"> <li>(i) pridobil razumevanje koncepta neparometričnega modeliranja z nevronskimi mrežami,</li> <li>(ii) znal razložiti poglavitne arhitekture nevronskih mrež (večnivojski perceptron, dinamične nevronske mreže, mreže radialnih baznih funkcij, samo-organizirajoče se mreže),</li> <li>(iii) razvil sposobnost izgradnje nevronskih mrež za reševanje realnih problemov,</li> <li>(iv) zmožen zasnovati ustrezno arhitekturo nevronske mreže, doseči dobre učne in posplošitvene rezultate, ter izdelati rešitev z nevronskimi mrežami.</li> </ul>	<p>The student will:</p> <ul style="list-style-type: none"> <li>(i) understand the concept of nonparametric modelling by neural networks,</li> <li>(ii) explain the most common NN architectures (multilayer perceptrons, dynamic networks, radial basis function networks, self-organized networks),</li> <li>(iii) develop the ability to construct neural networks for solving real-world problems,</li> <li>(iv) be able to design proper NN architecture, achieve good training and generalization performance, and finally, implement a neural network solution.</li> </ul>
---	---

<p><b>Metode poučevanja in učenja:</b></p> <p>Predavanja, laboratorijske vaje, seminarsko delo, e-izobraževanje, konzultacije. Seminarsko delo v čim večji meri navezuje se na področje doktorskega raziskovanja. Študij z uporabo priporočene literature.</p>	<p><b>Learning and teaching methods:</b></p> <p>Lectures, laboratory practice &amp; seminar work, e-education, consulting. The seminar work is related, as much as possible, to the student's doctoral research field. Study on a recommended literature basis.</p>
--	---

Načini ocenjevanja:	Delež/Weight	Assessment:
<p>Ocena je sestavljena iz seminarja (100%). Ocena seminarja je sestavljena iz pisnega dela (40%) in predstavitve ter ustnega zagovora (60%).</p>		<p>The grade is determined from the seminar (100%). The seminar grade consists of the written part (40%), presentation and oral defence (60%).</p>

<p><b>Reference nosilca/Lecturer's references:</b></p> <p><b>prof. dr. Edvard GOVEKAR</b>  BERLEC, Tomaž, POTOČNIK, Primož, GOVEKAR, Edvard, STARBEK, Marko. A method of production fine layout planning based on self-organising neural network clustering. International Journal of Production Research, ISSN 0020-7543, 2014, vol. 52, iss. 24, str. 7209-7222.  16. FLORJANIČ, Blaž, GOVEKAR, Edvard, KUZMAN, Karl. Neural network-based model for supporting the expert driven project estimation process in mold manufacturing. Strojniški vestnik, ISSN 0039-2480, Jan. 2013, vol. 59, no. 1, str. 3-13.  BORŠTNIK, A., GOVEKAR, E., GRABEC, I. Modeling the field of laser welding melt pool by RBFNN. Dyn. contin. discrete impuls. syst., 2007, vol. 14, suppl. 1, pp. 227-231.</p>
---