


Документ подписан простой электронной подписью
Информация о владельце:
ФИО: Таскаев Сергей Валерьевич
Должность: Ректор
Дата подписания: 21.05.2026 01:14:19
Уникальный программный ключ:
891934b8c2cf7b6350cbe51cdda7096a877f61f7



МИНОБРНАУКИ РОССИИ
Федеральное государственное бюджетное образовательное
учреждение высшего образования
«Челябинский государственный университет» (ФГБОУ ВО «ЧелГУ»)
Миасский филиал
Кафедра прикладной математики

Фонд оценочных средств по дисциплине «Функциональное программирование» по направлению подготовки 01.03.02 Прикладная математика и информатика, профиль «Математическое моделирование» ФГБОУ ВО «ЧелГУ»			
Версия документа - 1	стр. 1 из 2	Первый экземпляр _____	КОПИЯ № _____

**Фонд оценочных средств
для промежуточной аттестации**

по дисциплине

Функциональное программирование

Направление подготовки
01.03.02 Прикладная математика и информатика

Направленность (профиль)
Математическое моделирование

Присваиваемая квалификация
бакалавр

Форма обучения
очная

Миасс 2026 г.

01.03.02 Прикладная математика и информатика, Математическое моделирование, Функциональное программирование, 2026, очная

Фонд оценочных средств одобрен и рекомендован:

Проректор по учебной работе утверждено 27.02.26 А.А. Саламатов

Ученым советом Миасского филиала ФГБОУ ВО "ЧелГУ"

Протокол заседания № 8 от 24.02.2026

Председатель Ученого совета
Миасского филиала ФГБОУ ВО
"ЧелГУ"

согласовано

Т.В. Малькова

Заседанием кафедры прикладной математики

Протокол заседания № 6 от 30.01.2026

Заведующий кафедрой


согласовано

Е.В. Дутикова

Автор (составитель)

К.А. Лихачев

Структура рабочей программы соответствует приказу ректора ФГБОУ ВО «ЧелГУ» от «13» апреля 2021 г. № 247-1

	МИНОБРНАУКИ РОССИИ Федеральное государственное бюджетное образовательное учреждение высшего образования «Челябинский государственный университет» (ФГБОУ ВО «ЧелГУ») Миасский филиал Кафедра прикладной математики		
	Фонд оценочных средств по дисциплине «Функциональное программирование» по направлению подготовки 01.03.02 Прикладная математика и информатика, профиль «Математическое моделирование» ФГБОУ ВО «ЧелГУ»		
Версия документа - 1	стр. 3 из 25	Первый экземпляр _____	КОПИЯ № _____

1. ПАСПОРТ ФОНДА ОЦЕНОЧНЫХ СРЕДСТВ

Направление подготовки: 01.03.02 «Прикладная математика и информатика»

Направленность (профиль): Математическое моделирование

Дисциплина: Функциональное программирование

Семестр изучения: 8

Форма промежуточной аттестации: зачет

2. ПЕРЕЧЕНЬ ФОРМИРУЕМЫХ КОМПЕТЕНЦИЙ И ЭТАПЫ ИХ ФОРМИРОВАНИЯ

2.1. Компетенции, закреплённые за дисциплиной

Изучение дисциплины «Функциональное программирование» направлено на формирование следующих компетенций:

Коды компетенции (по ФГОС)	Содержание компетенций согласно ФГОС	Индикаторы достижения компетенций в соответствии с ОПОП	Перечень планируемых результатов обучения по дисциплине
УК-4	Способен осуществлять деловую коммуникацию в устной и письменной формах на государственном языке Российской Федерации и иностранном(ых) языке(ах)	УК-4.1 Имеет представление о правилах и принципах деловой устной и письменной коммуникации на государственном языке Российской Федерации и иностранном(ых) языке(ах). УК-4.2 Демонстрирует умение осуществлять деловую коммуникацию в устной и письменной формах, использовать методы и навыки делового общения. УК-4.3 Имеет навыки делового общения на государственном языке Российской Федерации и иностранном(ых) языке(ах)	<i>Знать</i> терминологию предметной области на английском языке <i>Уметь</i> переводить на русский язык документацию программ на английском языке; <i>Владеть</i> навыками чтения и понимания документации программ на английском языке;
ПК-2	Способен использовать базовые алгоритмы и	ПК-2.1 Демонстрирует знание основных принципов и технологий разработки программного обеспечения,	<i>Знать</i> основные методы разработки интеллектуальных систем, ключевые термины в



МИНОБРНАУКИ РОССИИ
Федеральное государственное бюджетное образовательное
учреждение высшего образования
«Челябинский государственный университет» (ФГБОУ ВО «ЧелГУ»)
Миасский филиал
Кафедра прикладной математики

Фонд оценочных средств по дисциплине «Функциональное программирование»
по направлению подготовки 01.03.02 Прикладная математика и информатика, профиль «Математическое моделирование»
ФГБОУ ВО «ЧелГУ»


Версия документа - 1

стр. 4 из 25

Первый экземпляр _____

КОПИЯ № _____

	средства проектирования программного обеспечения	<p>методов и средств сборки модулей и компонент программного обеспечения; разработки процедур для развертывания программного обеспечения, методов и средств миграции и преобразования данных, методов создания пользовательских интерфейсов; средств программирования</p> <p>ПК-2.2 Демонстрирует умения разрабатывать программный код на языках программирования высокого и низкого уровня, осуществлять отладку программ, оформлять техническую документацию; использовать выбранную среду программирования для разработки процедур интеграции программных модулей, проводить оценку работоспособности программного обеспечения</p> <p>ПК-2.3 Имеет практический опыт разработки исходного кода, тестирования программного обеспечения, сборки модулей и компонент программного обеспечения, разработки процедур для развертывания программного обеспечения, миграции и преобразования данных, создания программных интерфейсов</p>	<p>области искусственного интеллекта и интеллектуальных систем</p> <p><i>Уметь</i> использовать существующие библиотеки и инструментальные средства для разработки интеллектуальных систем</p> <p><i>Владеть</i> навыками проектирования интеллектуальных систем, навыками анализа и моделирования предметной области</p>
--	--	---	---

	МИНОБРНАУКИ РОССИИ Федеральное государственное бюджетное образовательное учреждение высшего образования «Челябинский государственный университет» (ФГБОУ ВО «ЧелГУ») Миасский филиал Кафедра прикладной математики		
	Фонд оценочных средств по дисциплине «Функциональное программирование» по направлению подготовки 01.03.02 Прикладная математика и информатика, профиль «Математическое моделирование» ФГБОУ ВО «ЧелГУ»		
Версия документа - 1	стр. 5 из 25	Первый экземпляр _____	КОПИЯ № _____

3. СОДЕРЖАНИЕ ОЦЕНОЧНЫХ СРЕДСТВ ПО ДИСЦИПЛИНЕ

3.1. Виды оценочных средств

№ п/п	Контролируемые темы/ разделы	Код компетенции/ планируемые результаты обучения	Наименование оценочного средства для текущего контроля	Наименование оценочного средства на промежуточной аттестации
1	Парадигмы программирования. Три основные парадигмы, их особенности и различия Обзор функциональных языков программирования, сравнение с другими современными языками и между собой	УК-4 <i>Знает</i> терминологию предметной области на английском языке ПК-2 <i>Знает</i> основные методы разработки интеллектуальных систем, ключевые термины в области искусственного интеллекта и интеллектуальных систем <i>Умеет</i> использовать существующие библиотеки и инструментальные средства для разработки интеллектуальных систем <i>Владеет</i> навыками проектирования интеллектуальных систем, навыками анализа и моделирования предметной области	Перевод статей по информационным технологиям с английского на русский язык. Задачи для контрольных работ	Тест, вопросы к зачету
2	Основы функционального программирования. Базовый синтаксис языка F# (и сравнение с Haskell). Операторы в языке F# (и сравнение с Haskell). Создание собственных операторов. Базовые типы в языке F# (и сравнение с Haskell). Коллекции: Списки и Массивы, операции над	УК-4 <i>Умеет</i> переводить на русский язык документацию программ на английском языке; <i>Владеет</i> навыками чтения и понимания документации программ на английском языке; ПК-2 <i>Владеет</i> навыками	Перевод статей по информационным технологиям с английского на русский язык. Задачи для контрольных работ	Тест, вопросы к зачету



МИНОБРНАУКИ РОССИИ
Федеральное государственное бюджетное образовательное
учреждение высшего образования
«Челябинский государственный университет» (ФГБОУ ВО «ЧелГУ»)
Миасский филиал
Кафедра прикладной математики

Фонд оценочных средств по дисциплине «Функциональное программирование»
по направлению подготовки 01.03.02 Прикладная математика и информатика, профиль «Математическое моделирование»
ФГБОУ ВО «ЧелГУ»

Версия документа - 1

стр. 6 из 25

Первый экземпляр _____

КОПИЯ № _____

списками, элементы стандартной библиотеки. Ленивые коллекции: Последовательности, операции над последовательностями, элементы стандартной библиотеки	проектирования интеллектуальных систем, навыками анализа и моделирования предметной области		
--	---	--	--

Типовые задания, критерии и показатели оценивания в рамках текущего контроля представлены в рабочей программе дисциплины (модуля). Полные комплекты оценочных средств и контрольно-измерительных материалов хранятся на кафедре.

3.2. Содержание оценочных средств

Оценочные средства представлены набором задач для проведения контрольных работ, выполняемых студентами в заданные сроки, тестом и набором задач, предполагающих компьютерную реализацию, оцениваемую преподавателем в присутствии экзаменуемого.

Задачи для проведения контрольных работ.

1 вариант

1. Основные понятия и определения искусственного интеллекта.
2. Язык функционального программирования: Erlang

2 вариант

1. Функциональная структура систем искусственного интеллекта.
2. Язык функционального программирования: Haskell

3 вариант

1. Определение процесса решения проблемной задачи.
2. Язык функционального программирования: F#

Вопросы для собеседования

1. Данные и знания. Роль знаний в процессе решения задач.
2. Базы знаний. Переход от базы данных к базе знаний
3. Понятия обучение и самообучение.
4. Обучение с использованием генетических алгоритмов.
5. Нейронные сети и используемые для них методы обучения.
6. Семантические сети, фреймы, сценарии.



МИНОБРНАУКИ РОССИИ
Федеральное государственное бюджетное образовательное
учреждение высшего образования
«Челябинский государственный университет» (ФГБОУ ВО «ЧелГУ»)
Миасский филиал
Кафедра прикладной математики

Фонд оценочных средств по дисциплине «Функциональное программирование»
по направлению подготовки 01.03.02 Прикладная математика и информатика, профиль «Математическое моделирование»
ФГБОУ ВО «ЧелГУ»

Версия документа - 1

стр. 7 из 25

Первый экземпляр _____

КОПИЯ № _____

7. Представления знаний для структурированных объектов, инженерия знаний.

8. Языки программирования и инструментальные средства, используемые для разработки систем искусственного интеллекта.

9. Технология проектирования и разработки экспертных систем.

10. Архитектура аппаратных средств ЭВМ для реализации искусственного интеллекта.

Пример статьи для перевода



SCIENTIFIC REPORTS

OPEN

Using human brain activity to guide machine learning

Ruth C. Fong^{1,3}, Walter J. Scheirer^{2,3} & David D. Cox³

Received: 16 March 2017
Accepted: 2 August 2017
Published online: 29 March 2018

Machine learning is a field of computer science that builds algorithms that learn. In many cases, machine learning algorithms are used to recreate a human ability like adding a caption to a photo, driving a car, or playing a game. While the human brain has long served as a source of *inspiration* for machine learning, little effort has been made to directly use data collected from working brains as a *guide* for machine learning algorithms. Here we demonstrate a new paradigm of “neurally-weighted” machine learning, which takes fMRI measurements of human brain activity from subjects viewing images, and infuses these data into the training process of an object recognition learning algorithm to make it more consistent with the human brain. After training, these neurally-weighted classifiers are able to classify images without requiring any additional neural data. We show that our neural-weighting approach can lead to large performance gains when used with traditional machine vision features, as well as to significant improvements with already high-performing convolutional neural network features. The effectiveness of this approach points to a path forward for a new class of hybrid machine learning algorithms which take both inspiration and direct constraints from neuronal data.

Recent years have seen a renaissance in machine learning and machine vision, led by neural network algorithms that now achieve impressive performance on a variety of challenging object recognition and image understanding tasks^{1–3}. Despite this rapid progress, the performance of machine vision algorithms continues to trail humans in many key domains, and tasks that require operating with limited training data or in highly cluttered scenes are particularly difficult for current algorithms^{4–7}. Moreover, the patterns of errors made by today’s algorithms differ dramatically from those of humans performing the same tasks^{8,9}, and current algorithms can be “fooled” by subtly altering images in ways that are imperceptible to humans, but which lead to arbitrary misclassifications of objects^{10–12}. Thus, even when algorithms do well on a particular task, they do so in a way that differs from how humans do it and that is arguably more brittle.

The human brain is a natural frame of reference for machine learning, because it has evolved to operate with extraordinary efficiency and accuracy in complicated and ambiguous environments. Indeed, today’s best algorithms for learning structure in data are artificial neural networks^{13–15}, and strategies for decision making that incorporate cognitive models of Bayesian reasoning¹⁶ and exemplar learning¹⁷ are prevalent. There is also growing overlap between machine learning and the fields of neuroscience and psychology: In one direction, learning algorithms are used for fMRI decoding^{18–21}, neural response prediction^{22–26}, and hierarchical modeling^{27–29}. Concurrently, machine learning algorithms are also leveraging biological concepts like working memory³⁰, experience replay³¹, and attention^{32,33} and are being encouraged to borrow more insights from the inner workings of the human brain³⁴. Here we propose an even more direct connection between these fields: we ask if we can improve machine learning algorithms by explicitly guiding their training with measurements of brain activity, with the goal of making the algorithms more human-like.

Our strategy is to bias the solution of a machine learning algorithm so that it more closely matches the internal representations found in visual cortex. Previous studies have constrained learned models via human behavior³⁵, and one work introduced a method to determine a mapping from images to “brain-like” features extracted from EEG recordings³⁶. Furthermore, recent advances in machine learning have focused on improving feature representation, often in a biologically-consistent way³⁸, of different kinds of data. However, no study to date has taken advantage of measurements of brain activity to guide the decision making process of machine learning. While

¹Department of Engineering Science, University of Oxford, Information Engineering Building, Oxford, OX1 3PJ, United Kingdom. ²Department of Computer Science and Engineering, University of Notre Dame, Fitzpatrick Hall of Engineering, Notre Dame, IN, 46556, USA. ³Department of Molecular and Cellular Biology, School of Engineering and Applied Sciences and Center for Brain Science, Harvard University, 52 Oxford St., Cambridge, MA, 02138, USA. R.C. Fong and W.J. Scheirer contributed equally to this work. Correspondence and requests for materials should be addressed to D.D.C. (email: davidcox@fas.harvard.edu)



our understanding of human cognition and decision making is still limited, we describe a method with which we can leverage the human brain's robust representations to guide a machine learning algorithm's decision boundary. Our approach weights how much an algorithm learns from each training exemplar, roughly based on the "ease" with which the human brain appears to recognize the example as a member of a class (i.e., an image in a given object category). This work builds on previous machine learning approaches that weight training^{8,37}, but here we propose to do such weighting using a separate stream of data, derived from human brain activity.

Below, we describe our biologically-informed machine learning paradigm in detail, outline an implementation of the technique, and present results that demonstrate its potential to learn more accurate, biologically-consistent decision-making boundaries. We trained supervised classification models for four, visual object categories (i.e., humans, animals, places, foods), weighting individual training images by values derived from fMRI recordings in human visual cortex viewing those same images; once trained, these models classify images without the benefit of neural data.

Our "neurally-weighted" models were trained on two kinds of image features: 1., histogram of oriented gradients (HOG) features³⁸ and 2., convolutional neural network (CNN) features (i.e., 1000-dimensional, pre-softmax activations from AlexNet¹³ pre-trained on the ImageNet dataset¹). HOG features were the standard, off-the-shelf image feature representation before the 2012 advent of powerful CNNs¹, while CNNs pre-trained on large datasets like ImageNet are known to be strong, general image features, which can transfer well to other tasks^{39,40}. While machine vision research has largely focused on improving feature representation in order to make gains in various, challenging visual tasks, another complementary approach, which our paradigm falls under, is to improve the decision making process. Thus, we hypothesized that our decision boundary-biasing paradigm would yield larger gains when coupled with the weaker HOG features, thereby enabling HOG features to be more competitive to the stronger CNN features.

Finally, these models were then evaluated for improvement in baseline performance as well as analyzed to understand which regions of interest (ROIs) in the brain had greater impact on performance.

Results

Visual cortical fMRI data were taken from a previous study conducted by the Gallant lab at Berkeley⁴¹. One adult subject viewed 1,386 color 500 × 500 pixel images of natural scenes, while being scanned in a 3.0 Tesla (3T) magnetic resonance imaging (MRI) machine. After fMRI data preprocessing, response amplitude values for 67,600 voxels were available for each image. From this set of voxels, 3,569 were labeled as being part of one of thirteen visual ROIs, including those in the early visual cortex. Seven of these regions were associated with higher-level visual processing; all seven higher-level ROIs were used in object category classification tasks probing the semantic understanding of visual information (only the higher-level ROIs were used due to the semantic nature of the classification tasks; earlier regions typically capture low- to mid-level features like edges in V1^{42,43} and colors and shapes in V4^{44,45}): extrastriate body area (EBA), fusiform face area (FFA), lateral occipital cortex (LO), occipital face area (OFA), parahippocampal place area (PPA), retrosplenial cortex (RSC), transverse occipital sulcus (TOS). 1,427 voxels belonged to these regions.

In machine learning, loss functions are used to assign penalties for misclassifying data; then, the objective of the algorithm is to minimize loss. Typically, a *hinge loss* function (Eq. 1) is used for classic maximum-margin binary classifiers like Support Vector Machine (SVM) models⁴⁶:

$$\phi_h(z) = \max(0, 1 - z) \quad (1)$$

where $z = y \cdot f(x)$, $y \in \{-1, +1\}$ is the true label, and $f(x) \in \mathbb{R}$ is the predicted output; thus, z denotes the correctness of a prediction. The HL function assigns a penalty to all misclassified data that is proportional to how erroneous the prediction is.

However, incorporating brain data into a machine learning model relies on the assumption that the intensity of a pattern of activation in a region represents the neuronal response to a visual stimulus. A strong response signals that a stimulus is more associated with a particular visual area, while a weaker response indicates that the stimulus is less associated with it⁴⁷. Here, the proposed *activity weighted loss* (AWL) function (Eq. 2) embodies this strategy by proportionally penalizing misclassified training samples based on any inconsistency with the evidence of human decision making found in the fMRI measurements, in addition to using the typical HL penalty:

$$\phi_s(x, z) = \max(0, (1 - z) \cdot M(x, z)) \quad (2)$$

where

$$M(x, z) = \begin{cases} 1 + c_x, & \text{if } z < 1 \\ 1, & \text{otherwise} \end{cases} \quad (3)$$

and $c_x \geq 0$ is an activity weight derived from fMRI data corresponding to x .

In its general form with an unknown method of generating activity weights, AWL penalizes more aggressively the misclassification of stimuli x with large activity weight c_x . The proposed paradigm involves training a binary SVM classifier on fMRI voxel activity and using Platt probability scores as activity weights. With this method, a large activity weight c_x denotes that the fMRI activity corresponding to visual stimulus x is predicted with high confidence to be a positive example for a given binary classification task. There are several possible explanations of what a large activity weight c_x connotes about visual stimulus x : 1. it corresponds well to a canonical neural response pattern for the positive class, and 2. its highly confident predictive quality suggests that more upstream parts of the visual cortex would recognize its corresponding image with ease. The second explanation is difficult to test without further data of human recognition quality. However, it was qualitatively observed that visual



Figure 1. Experimental workflow for biologically-informed machine learning using fMRI data. (A) fMRI was used to record BOLD voxel responses of one subject viewing 1,386 color images of natural scenes, providing labelled voxels in several conventional, functional ROIs (i.e., EBA, FFA, LO, OFA, PPA, RSC, and TOS)⁴¹. (B) For a given binary object category classification task (e.g., whether a stimulus contains an animal), the visual stimuli and voxel activity data were split into training and test sets (not shown). An SVM classifier was trained and tested on voxel activity alone. (C) To generate activity weights, classification scores, which roughly correspond to the distance of a sample from the decision boundary in (B), were transformed into a probability value via a logistic function⁴⁸. (D,E) The effects of using activity weights were assessed by training and testing two classification models on image features of the visual stimuli: (D) One SVM classifier used a loss function (i.e., hinge loss [HL]) that equally weights the misclassification of all samples as a function of distance from the SVM's own decision boundary. (E) Another SVM classifier used a modified loss function (i.e., activity weighted loss [AWL]) that penalizes more aggressively the misclassification of samples with large activity weights. In training, these classifiers in (D) and (E) only had access to activity weights generated in (C); in testing, the classifiers used no neural data and made predictions based on image features alone. (Images used in this figure are from⁶⁹ and are freely available via <https://creativecommons.org/publicdomain/zero/1.0/CC01.0>).

stimuli with large activity weights were clear positive examples (i.e., a single, dominant object of the class of interest in the image, like the one in the bottom right of Panel C in Fig. 1), providing evidence for the first explanation.

With this formulation, not all training samples require an fMRI-generated activity weight. Note that $c_x = 0$ reduces the AWL function to a HL function and can be assigned to samples for which fMRI data is unavailable. AWL is inspired by previous work⁸, which introduced a loss function that additively scaled misclassification penalty by information derived from behavioral data. AWL replaces the standard HL function (Eq. 1) in the objective of the SVM algorithm, which does not have access to any information other than a feature vector and an arbitrary class label for each training sample in its original form.

Experiments were conducted for the 127 ways that the seven higher-level visual cortical regions could be combined. In each experiment, for a given combination of ROIs and a given object category, the following two-phase procedure was carried out (Fig. 1):

1. Generate activity weights $\{c_x\}$ by calibrating the scores of a Radial Basis Function (RBF) kernel SVM binary classifier, e.g., $f_f: X_f \rightarrow [0,1]$, trained on the training voxel data for the combination into probabilities via a logistic transformation⁴⁸ (Fig. 1A–C). $x_{f(i)} \in X_f$ is a vector containing the response amplitudes for all the voxels in a given ROI combination that were recorded when the subject was viewing image x_i , and the resulting probability $c_{x_i} = f_f(x_{f(i)})$ connotes how likely voxel activity x was recorded when the subject was viewing an image in a given object category, e.g., humans. fMRI-based activity weights were only generated for voxel activity associated with images that were clear positive and negative examples of a given class. For all other examples (e.g., images that contained multiple classes, such as a person with a pet animal), $c_{x_i} = 0$.
2. Create five balanced classification problems (Fig. S1). For each balanced problem and a set of image descriptors, train and test two binary SVM classification models, e.g., $f_H: X_H \rightarrow \{-1, +1\}$, with an RBF-kernel—one that used the HL function and another that used an AWL function conditioned on the activity weights $\{c_x\}$ from the first step (Fig. 1D and E). Two image features were considered: HOG is a handcrafted feature that is approximately V1-like^{38,49}, CNNs are learned feature representations that

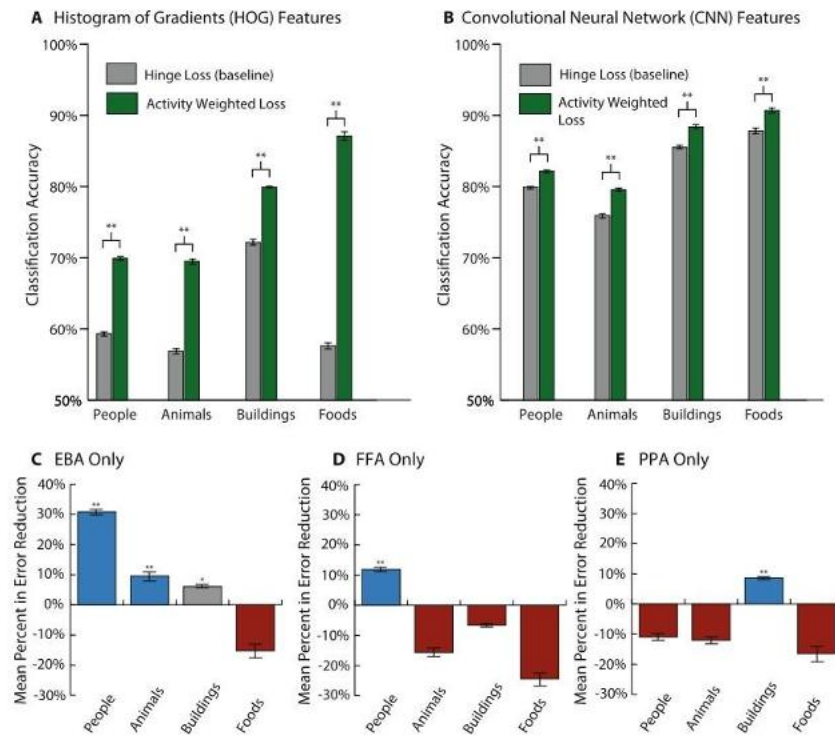


Figure 2. Results showing the effect of conditioning classification models for four visual classes on fMRI data during supervised training (Fig. 1). (A,B) Side-by-side comparisons of the mean classification accuracy between models that were trained using either (A) HOG features or (B) CNN features and either a hinge loss (HL) or activity weighted loss (AWL) function. These graphs show results of experiments that generated activity weights by using voxels from all seven higher-level visual ROIs (i.e., EBA, FFA, LO, OFA, PPA, RSC, and TOS). For each object category and choice of image features, the models trained using AWL were significantly better ($p < 0.01$ via paired, one-tailed t-testing). While using AWL loss reduces misclassification error using both features, it particularly improves the performance of handcrafted HOG features. (C–E) Mean error reductions gained by switching from HL to AWL loss when using conditioning classifies on brain activity from individual ROIs (i.e., EBA, FFA, or PPA) show that certain areas produce significantly better results for the specific categories they are selective for. Error bars are standard error over 20 trials in all cases.

approximate several additional layers of the ventral stream^{14,22}. $x_{T(i)} \in X_T$ is a vector containing either HOG or CNN features for image x_i .

Experiments were performed for four object categories: humans, animals, buildings, and foods; see methods for more details.

We demonstrate that using activity weights derived from all of the higher visual cortical regions significantly improves classification accuracy across all four object categories via paired, one-tailed testing (Fig. 2A and B). A substantial amount of fMRI decoding literature focuses on three ROIs: EBA, FFA, and PPA^{50–52}. This is in part because these three regions are thought to respond to visual cues of interest for the study of object recognition: body parts, faces, and places respectively. Given the overlap between these visual cues and the four object categories used, we hypothesized that activity weights derived from brain activity in these three regions would significantly improve classification accuracy for the humans, animals, and buildings categories only in instances where a response would be expected. For example, PPA was expected to improve the buildings category but to have little, if any, effect on the humans category (Fig. 2E). A comparison of models that used activity weights based on brain activity from these three regions and models that used no activity weights aligns well with the neuroimaging literature (Fig. 2C–E). Classification accuracy significantly improved not only when activity weights were derived from voxels in all seven ROIs or from voxels in the individual EBA, FFA, and PPA regions but also when activity weights were derived from voxels in most of the 127 ROI combinations (Fig. S2). We observed that adding fMRI-derived activity weights provided a large improvement to models using HOG features compared to those using CNN features (Fig. 2A and




Figure 3. Statistical influence of each ROI in binary object classification models using fMRI activity weighted loss (AWL) and HOG features. In each graph, the percentage of the 64 ROI combinations containing a specific ROI that had a mean classification accuracy greater than that of all 127 sets of experiments is plotted. The threshold for the 95% confidence interval ($p < 0.0004$) is overlaid, showing which ROIs significantly differed from the respective null distribution for each object category. Permutation tests and Bonferroni correction ($\alpha = 127$) were used. See Figure S3 for a similar plot for CNN features and Figures S4 and S5 for an explanation of how the null distribution was sampled.

B). These results suggest that improvements in decision making (e.g., the use of salient activity weights based on brain activity) may be able to compensate for poor feature representation (e.g., HOG features). They also imply that some of the information carried by activity weights may already be latently captured in CNN features. Despite their relatively smaller performance gains, activity weighted classifiers for CNN features still demonstrate that the state-of-the-art representation, which is often praised as being inspired by the mammalian ventral stream, does not fully capture all the salient information embedded in internal representations of objects in the human brain.

Additionally, statistical analysis by permutation was carried out to test whether the above-average mean accuracy rates observed in classification experiments for the humans and animals categories that included EBA, as well as in the experiments for the buildings and foods categories that included PPA, were statistically significant or products of random chance. For each object category and set of image features, a null distribution with 1,000,000 samples was generated. Each sample in the null distribution reflects the percentage that a random set of 64 ROI combinations would have a mean classification accuracy (i.e., averaged over 20 samples, $20 = 4$ partitions \times 5 balanced problems) that is greater than the overall mean classification accuracy averaged over all 127 mean classification accuracies. The aim is to test the significance of individual ROIs in generating salient activity weights that yield above-average classification accuracy rates. Thus, these samples simulate randomly assigning ROI labels to the 127 combinations. If individual ROIs did not significantly contribute to the above-average mean accuracy rates observed, above-average mean accuracy rates of combinations that include specific ROIs falling near the mean of the null distribution should be observed. To generate each of the 1,000,000 samples, 64 of the 127 ROI combinations were randomly selected. Then, a count was taken of how many of those 64 randomly selected combinations have a mean classification accuracy that is greater than the average of that of all 127 sets of experiments corresponding to the 127 total ROI combinations. A sample is normalized to represent a percentage by dividing this count by 64. Finally, the actual percentage of the 64 ROI combinations including a given ROI (e.g., all 64 ROI combinations that include EBA), that yield above-average mean classification accuracy when compared to the overall mean classification accuracy for all 127 combinations is compared to the null distribution.

When using HOG features to train activity-weighted loss SVMs to classify humans, 98.44% of the 64 combinations that include EBA yielded above-average accuracies, which well exceeded the null distribution of probable percentages if EBA did not have a significant effect in improving the classification accuracy. Figures S4 and S5 and accompanying supplementary text further detail how a null sample is generated. Figures 3 and S3 show which ROIs significantly differed from the respective null distributions for each object category. This analysis more rigorously confirms the significance of the EBA region in improving the classification accuracy of the humans and animals categories and of the PPA region in improving the accuracy of the buildings and foods categories. Most notably, the EBA region dramatically exceeds the significance thresholds of the null distributions for humans and animals.



МИНОБРНАУКИ РОССИИ
Федеральное государственное бюджетное образовательное
учреждение высшего образования
«Челябинский государственный университет» (ФГБОУ ВО «ЧелГУ»)
Миасский филиал
Кафедра прикладной математики

Фонд оценочных средств по дисциплине «Функциональное программирование»
по направлению подготовки 01.03.02 Прикладная математика и информатика, профиль «Математическое моделирование»
ФГБОУ ВО «ЧелГУ»

Версия документа - 1

стр. 13 из 25

Первый экземпляр _____

КОПИЯ № _____

www.nature.com/scientificreports/

Discussion

Our results provide strong evidence that information measured directly from the human brain can help a machine learning algorithm make better, more human-like decisions. As such, this work adds to a growing body of literature that suggests that it is possible to leverage additional “side-stream” data sources to improve machine learning algorithms⁵³. However, while measures of human behavior have been used extensively to guide machine learning via active learning^{54–57}, structured domain knowledge⁵⁸, and discriminative feature identification⁵⁹, this study suggests that one can harness measures of the internal representations employed by the brain to guide machine learning. We argue that this approach opens a new wealth of opportunities for fine-grained interaction between machine learning and neuroscience.

While this work focused on visual object recognition and fMRI data, the framework described here need not be specific to any one sensory modality, neuroimaging technique or supervised machine learning algorithm. Indeed, the approach can be applied generally to any sensory modality, and could even potentially be used to study multisensory integration, with appropriate data collection. Similarly, while fMRI has the advantage of measuring patterns of activity over large regions of the brain, one could also imagine applying our paradigm to neural data collected using other imaging methods in animals, including techniques that allow single cell resolution over cortical populations, such as two-photon imaging⁶⁰. Such approaches may allow more fine-grained constraints to be placed on machine learning, albeit at the expense of allowing the integration of data from smaller fractions of the brain.

There are several limitations with this first instantiation of the paradigm. First, we derived a scalar activity weight from high-dimensional fMRI voxel activity. This simple method yielded impressive performance gains and corresponded well to the notion of ease of recognition; however, much more meaningful information captured by the human brain is inevitably being ignored. Future biologically-informed machine learning research should focus on the development and infusion of low-dimensional activity weights, which may not only preserve more useful data but also reveal other dimensions that are important for various tasks, but are not yet learned by machine learning algorithms or captured in traditional datasets.

Another constraint on our specific experimental set-up was the limited amount and distribution of our data ($N = 1260$ images), which restricts us to considering broad object categories instead of fine-grained ones. It remains to be seen whether our paradigm would similarly bolster machine learning algorithms tasked to discriminate among fine-grained classes that are less clearly distinguished in the visual cortex (e.g., furniture, tools, sports equipment). Given how robustly humans can distinguish among numerous fine-grained categories that do not necessarily have dedicated visual processing regions, such as EBA for human body parts, we hypothesize that using brain activity from all higher-level ROIs (Fig. 2A and B) would yield similar improvements in performance for fine-grained classification tasks. However, we suspect that using activity from a single, higher-level ROI, such as EBA, FFA, or PPA (Fig. 2C–E), will not confer significant improvements and that no single higher-level ROI will be substantially influential (Fig. 2C–E), but rather, the aggregate semantic information encoded and distributed throughout all higher-level ROIs will be responsible for any observed benefits from biologically-informed training for fine-grain classification tasks.

Furthermore, while we demonstrated our biologically-informed paradigm using support vector machines, there is also flexibility in the choice of the learning algorithm itself. Our method can be applied to any learning algorithm with a loss formulation as well as extended to other tasks in regression and Bayesian inference. An analysis of different algorithms and their baseline and activity weighted performance could elucidate which algorithms are relatively better at capturing salient information encoded in the internal representations of the human brain²⁴.

Our paradigm currently requires access to biological data during training time that corresponds to the input data for a given task. For instance, in this work, we used fMRI recordings of human subjects viewing images to guide learning of object categories. Extending this work to new problem domains will require specific data from those problem domains, and this will in turn require either increased sharing of raw neuroimaging data, or close collaboration between neuroscientists and machine learning researchers. While this investigation used preexisting data to inform a decision boundary, one could imagine even more targeted collaborations between neuroscientists and machine learning researchers that tailor data collection to the needs of the machine learning algorithm. We argue that approaches such as ours provide a framework of common ground for such collaborations, from which both fields stand to benefit.

Methods

fMRI Data Acquisition. The fMRI data used for the machine learning experiments presented in this paper are a subset of the overall data from a published study on scene categorization⁴¹. All fMRI data were collected using a 3T Siemens Tim Trio MR scanner. For the functional data collection for one subject, a gradient-echo planar imaging sequence, combined with a custom fat saturation RF pulse, was used. Twenty-five axial slices covered occipital, occipitoparietal, and occipitotemporal cortex. Each slice had a $234 \times 234 \text{ mm}^2$ field of view, 2.60 mm slice thickness, and 0.39 mm slice gap (matrix size = 104×104 ; TR = 2,009.9 ms; TE = 35 ms; flip angle = 74°; voxel size = $2.25 \times 2.25 \times 2.99 \text{ mm}^3$). While⁴¹ recorded fMRI activity for four subjects, in this work, we only use the brain activity from one subject out of the original four. The experimental protocol was approved by the UC Berkeley Committee for the Protection of Human Subjects. All methods were performed in accordance with the relevant guidelines and regulations.

Data Set. The data set consisted of 1,386 500 × 500 color images of natural scenes from^{41,61}, which the subject viewed while his brain activity was being recorded (see⁴¹ for more details on the dataset). These images were used as both stimuli for the fMRI data collection, and as training data for the machine learning experiments. Within this collection, the training set consisted of 1,260 images and the testing set of 126 images. Per-pixel object labels



in the form of object outlines and semantically meaningful tags were available for each image. A subset of these labels were mapped to one of five object categories: humans, animals, buildings, foods, and vehicles. For each image and for each of the five object categories, if at least 20% of an image's original pixel labels were part of a given object category, that image was tentatively labeled as a positive sample for that category. We sampled 646 images that were labelled with a single object category. There were 219 humans images, 180 animals images, 151 buildings images, 59 foods images, and 37 vehicles images (a category, due to its small size, that only contributed negative examples).

fMRI Data Preprocessing. To perform motion correction, coregistration, and reslicing of functional images, the SPM8 package⁶² was used. Custom MATLAB⁶³ software was used to perform all other preprocessing of functional data. To constrain the dimensionality of the fMRI data, the time series recordings for each voxel were reduced to a single response amplitude per voxel, per image by deconvolving each time course from the stimulus design matrix using hemodynamic response function⁶⁴. See Stansbury *et al.*⁶¹ for additional details about the fMRI data acquisition and preparation that are not directly related to the machine learning experiments we describe in this work.

fMRI Activity Weight Calculation. All of the fMRI data were scaled to bring the value of each dimension within the range of [0, 1] for RBF SVM training. For each voxel, we calculated the minimum and maximum response amplitude across all 1,260 original training samples. All voxels for the 646 images used in our experiments were then scaled using Equation 4, where x_{ij} is the j -th sample's response amplitude for voxel i , \bar{x}_i is a 646-dimensional vector with the response amplitudes of all samples for voxel i , and x_{ij}' is the j -th sample's rescaled amplitude for voxel i .

$$x_{ij}' = \frac{x_{ij} - \min(\bar{x}_i)}{\max(\bar{x}_i) - \min(\bar{x}_i)} \quad (4)$$

The main challenge of generating weights from brain activity (i.e., activity weights) lies in reducing high-dimensional, nonlinear data to a salient, lower-dimensional signal of "learnability". The supervised machine learning formulation used in this work requires a single real valued weight per training sample for a loss function (described below). Activity weights were computed by using a logistic transformation⁶⁵ to calibrate the scores from SVMs with RBF kernels trained on brain activity. For each object category and for all voxels from a given combination of ROIs, we made use of all the positive samples for that object category as well as all the samples that are negative for all object categories; together, these are the aforementioned 646 samples (i.e., clear sample set). Only activity weights for this subset of a partition's training set, as opposed to annotations for all 1,386 stimuli were generated. This constraint maximized the signal-to-noise ratio in the activity weights and improved the saliency of activity weights for a specific object category by only weighting clear positive and negative samples.

Activity weights for training were generated using a modification of the k -fold cross validation technique. For a given training set that is a subset of the whole 1,386 set, the collection of voxel data for the training set's images in the 646-stimuli clear sample set was randomly split into five folds. For each of these folds, we held out the current fold as test data and combined the other four folds as training data. With this newly formed training set, a grid search was performed to tune the soft margin penalty parameter C and RBF parameter γ for an RBF SVM classifier using the LibSVM package⁶⁶. Finally, activity weights were generated by testing the classifier on the held-out fold to produce Platt probability scores⁶⁶ of class inclusion. This process was repeated for all five folds to generate activity weights for the collection of stimuli in the training set that are part of the clear sample set.

Experimental Design. Each of the original 500×500 colored images were down sampled to 250×250 grayscale images, with pixel values in the interval [0,1]. A layer of Gaussian noise with a mean of 0 and variance of 0.01 was added to each of these images. For each image, two feature descriptor types were independently generated. Histogram of Oriented Gradients (HOG) descriptors with a cell size of 32 were generated using the VLFeat library's `vl_hog` function⁶⁷, which computes UoCTTI HOG features⁶⁸. Convolutional neural network (CNN) features were generated using the Caffe library's BLVC Reference CaffeNet model¹⁴, which is AlexNet trained on ILSVRC 2012¹, with minor differences from the version described by Krizhevsky *et al.*¹³. 1000-dimension pre-softmax activations from CaffeNet were used as the CNN image features. Four partitions of training and test data were created. In each partition, 80% of the data was randomly designated as training data and the remaining 20% was designated as test data.

For each partition, experiments were conducted for the 127 ways that the seven higher-level visual cortical regions (i.e., EBA, FFA, LO, OFA, PPA, RSC, and TOS) could be combined. In each experiment, for a given combination of higher-level visual cortical regions and for a given object category, two training steps were followed:

1. Activity weights were generated for a sampling of training stimuli, ones that are part of the 646-stimuli clear sample set, using an RBF-kernel SVM classifier trained on the training voxel data for that combination, following the fMRI activity weight calculation procedure described above.

2. Five balanced classification problems were created from the given partition's training data. For each balanced classification problem and each set of image descriptors (HOG and CNN features), two SVM classifiers were trained and tested—one that uses a standard hinge loss (HL) function⁶⁷ and another that uses an activity weighted loss (AWL) function described by Equations 2 and 3. Both classifiers used an RBF-kernel.

The hinge loss function in Equation 1 is solved via Sequential Minimal Optimization⁶⁸. It is not necessary to assign an activity weight $c_x \in C$ derived from fMRI data to every training sample; c_x can be 0 to preserve the output of the original hinge loss function. In our experiments, $c_x \in [0, 1]$, where c_x corresponds to the probability



that x is in the object category in question; this results in penalizing more aggressively the misclassification of strong positive samples. The libSVM package was used to train and test SVM classifiers using a hinge loss function⁶⁵. To train classifiers using an activity weighted loss function, we modified publicly available code for an alternative additive loss formulation⁸.

For each object category, combination of higher visual cortical regions, and set of image descriptors, we created five balanced classification problems. For each problem, we created a balanced training set with an equal number of positive and negative examples. For all object categories, because there were more negative than positive samples, all positive samples were used in each balanced problem and the same number of negative samples were randomly selected for each balanced problem. The balanced problems only balanced the training data; each balanced problem used the same test set: the partition's held-out test set.

For both loss functions, binary SVM classifiers with RBF kernels were trained without any parameter tuning, using parameters $C = 1$ and $\gamma = 1/\text{number of features}$. The activity weighted loss function incorporates the calibrated probability scores from the first stage voxel classifiers as activity weights. We assigned these activity weights to the training samples that are members of the 646-stimuli clear samples set. For samples without fMRI-derived activity weights, activity weights of 0.0 are used. Finally, classifiers were tested on the partition's test set. In experiments using CNN features, RBF-kernel SVM classifiers converged during training, even though the vectors consisted of high-dimensional data.

Statistics for ROI Analysis. Because our analysis of the influence of specific ROIs involves comparing 127 quantities, to avoid multiple comparisons and to control for the family-wise error rate, Bonferroni correction was applied to adjust all confidence intervals. To create m individual confidence intervals with a collective confidence interval of $1 - \alpha$, the adjusted confidence intervals were calculated via $1 - \frac{\alpha}{m}$. With these adjusted confidence intervals ($m = 127$, $\alpha = 0.05$ and $\alpha = 0.01$), we compared the outputs of the empirical CDF function $F_X(x)$ for each null distribution X that corresponded to an object category and set of image features as well as each ROI.

Data availability. The fMRI and image data that support the findings of this study are from Stansbury *et al.*⁴¹ and are available from them on reasonable request.

References

1. Russakovsky, O. *et al.* Imagenet large scale visual recognition challenge. *IJCV* **115**, 1–42 (2014).
2. Karpathy, A. *et al.* Large-scale video classification with convolutional neural networks. In *IEEE CVPR* (2014).
3. Karpathy, A. & Fei-Fei, L. Deep visual-semantic alignments for generating image descriptions. In *IEEE CVPR* (2015).
4. Borji, A., Sihite, D. N. & Itti, L. Quantitative analysis of human-model agreement in visual saliency modeling: A comparative study. *IEEE T-IP* **22**, 55–69 (2013).
5. Borji, A. & Itti, L. Human vs. computer in scene and object recognition. In *IEEE CVPR* (2014).
6. Bendale, A. & Boulton, T. Towards open world recognition. In *IEEE CVPR* (2015).
7. Hoiem, D., Chodpathumwan, Y. & Dai, Q. Diagnosing error in object detectors. In *ECCV* (2012).
8. Scheirer, W. J. *et al.* Perceptual annotation: Measuring human vision to improve computer vision. *IEEE T-PAMI* **36**, 1679–1686 (2014).
9. Pramod, R. & Arun, S. Do computational models differ systematically from human object perception? In *IEEE CVPR* (2016).
10. Szegedy, C. *et al.* Intriguing properties of neural networks. In *ICLR* (2014).
11. Goodfellow, I., Shlens, J. & Szegedy, C. Explaining and harnessing adversarial examples. In *ICLR* (2015).
12. Nguyen, A., Yosinski, J. & Clune, J. Deep neural networks are easily fooled: High confidence predictions for unrecognizable images. In *IEEE CVPR* (2015).
13. Krizhevsky, A., Sutskever, I. & Hinton, G. E. Imagenet classification with deep convolutional neural networks. In *NIPS* (2012).
14. Jia, Y. *et al.* Caffe: Convolutional architecture for fast feature embedding. *CoRR abs/1408.5093*, <http://arxiv.org/abs/1408.5093> (2014).
15. Mnih, V. *et al.* Human-level control through deep reinforcement learning. *Nature* **518**, 529–533 (2015).
16. Tenenbaum, J. B., Griffiths, T. L. & Kemp, C. Theory-based bayesian models of inductive learning and reasoning. *Trends in Cog. Sci.* **10**, 309–318 (2006).
17. Jäkel, F. *et al.* Does cognitive science need kernels? *Trends in Cog. Sci.* **13**, 381–388 (2009).
18. Kay, K. *et al.* Identifying natural images from human brain activity. *Nature* **452**, 352–355 (2008).
19. Mitchell, T. M. *et al.* Predicting human brain activity associated with the meanings of nouns. *Science* **320**, 1191–1195 (2008).
20. Naselaris, T. *et al.* Bayesian reconstruction of natural images from human brain activity. *Neuron* **63**, 902–915 (2009).
21. Reddy, L., Tsuchiya, N. & Serre, T. Reading the mind's eye: decoding category information during mental imagery. *Neuroimage* **50**, 818–825 (2010).
22. Yamins, D. *et al.* Hierarchical modular optimization of convolutional networks achieves representations similar to macaque it and human ventral stream. In *NIPS*, 3093–3101 (2013).
23. Yamins, D. *et al.* Performance-optimized hierarchical models predict neural responses in higher visual cortex. *PNAS* **111**, 8619–8624 (2014).
24. Kriegeskorte, N., Mur, M. & Bandettini, P. Representational similarity analysis—connecting the branches of systems neuroscience. *Front. in Sys. Neuro.* **2** (2008).
25. Agrawal, P. *et al.* Pixels to voxels: Modeling visual representation in the human brain. *arXiv:1407.5104* (2014).
26. Cichy, R. M., Khosla, A., Pantazis, D., Torralba, A. & Oliva, A. Deep neural networks predict hierarchical spatio-temporal cortical dynamics of human visual object recognition. *arXiv preprint arXiv:1601.02970* (2016).
27. Riesenhuber, M. & Poggio, T. Hierarchical models of object recognition in cortex. *Nature Neuroscience* **2**, 1019–1025 (1999).
28. Serre, T., Oliva, A. & Poggio, T. A feedforward architecture accounts for rapid categorization. *PNAS* **104**, 6424–6429 (2007).
29. Pinto, N. *et al.* A high-throughput screening approach to discovering good forms of biologically inspired visual representation. *PLoS Computational Biology* **5** (2009).
30. Graves, A. *et al.* Hybrid computing using a neural network with dynamic external memory. *Nature* **538**, 471–476 (2016).
31. Mnih, V. *et al.* Human-level control through deep reinforcement learning. *Nature* **518**, 529–533 (2015).
32. Gregor, K., Danihelka, I., Graves, A., Rezende, D. J. & Wierstra, D. Draw: A recurrent neural network for image generation. *arXiv preprint arXiv:1502.04623* (2015).
33. Xu, K. *et al.* Show, attend and tell: Neural image caption generation with visual attention. *arXiv preprint arXiv:1502.03044* **2**, 5 (2015).



34. Lake, B. M., Ullman, T. D., Tenenbaum, J. B. & Gershman, S. J. Building machines that learn and think like people. *arXiv preprint arXiv:1604.00289* (2016).
35. Chen, D., Li, S., Kourtzi, Z. & Wu, S. Behavior-constrained support vector machines for fMRI data analysis. *IEEE T-NN* **21**, 1680–1685 (2010).
36. Spampinato, C. *et al.* Deep learning human mind for automated visual classification. *arXiv preprint arXiv:1609.00344* (2016).
37. Bengio, Y., Louradour, J., Collobert, R. & Weston, J. Curriculum learning. In *Proceedings of the 26th annual international conference on machine learning*, 41–48 (ACM, 2009).
38. Dalal, N. & Triggs, B. Histograms of oriented gradients for human detection. In *IEEE CVPR* (2005).
39. Oquab, M., Bottou, L., Laptev, I. & Sivic, J. Learning and transferring mid-level image representations using convolutional neural networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 1717–1724 (2014).
40. Wang, N., Li, S., Gupta, A. & Yeung, D.-Y. Transferring rich feature hierarchies for robust visual tracking. *arXiv preprint arXiv:1501.04587* (2015).
41. Stansbury, D., Naselaris, T. & Gallant, J. L. Natural scene statistics account for the representation of scene categories in human visual cortex. *Neuron* **79**, 1025–1034 (2013).
42. Lee, T. S., Mumford, D., Romero, R. & Lamme, V. A. The role of the primary visual cortex in higher level vision. *Vision research* **38**, 2429–2454 (1998).
43. Marr, D. & Hildreth, E. Theory of edge detection. *Proceedings of the Royal Society of London B: Biological Sciences* **207**, 187–217 (1980).
44. Lueck, C. *et al.* The colour centre in the cerebral cortex of man. *Nature* **340**, 386–389 (1989).
45. Desimone, R. & Schein, S. J. Visual properties of neurons in area v4 of the macaque: sensitivity to stimulus form. *Journal of neurophysiology* **57**, 835–868 (1987).
46. Cortes, C. & Vapnik, V. Support-vector networks. *Machine learning* **20**, 273–297 (1995).
47. Kanwisher, N., Stanley, D. & Harris, A. The fusiform face area is selective for faces not animals. *Neuroreport* **10**, 183–187 (1999).
48. Platt, J. Probabilistic outputs for support vector machines and comparison to regularized likelihood methods. In Smola, A., Bartlett, P. & Schölkopf, B. (eds.) *Advances in Large Margin Classifiers* (MIT Press, 2000).
49. Vedaldi, A. & Fulkerson, B. VLFeat: An open and portable library of computer vision algorithms. <http://www.vlfeat.org/> (2008).
50. Cox, D. D. & Savoy, R. L. Functional magnetic resonance imaging (fMRI) brain reading: detecting and classifying distributed patterns of fMRI activity in human visual cortex. *Neuroimage* **19**, 261–270 (2003).
51. Kriegeskorte, N. *et al.* Individual faces elicit distinct response patterns in human anterior temporal cortex. *PNAS* **104**, 20600–20605 (2007).
52. Spiridon, M., Fischl, B. & Kanwisher, N. Location and spatial profile of category-specific regions in human extrastriate cortex. *Hum. Brain Mapp.* **27**, 77–89 (2006).
53. Vondrick, C., Pirsiavash, H., Oliva, A. & Torralba, A. Acquiring visual classifiers from human imagination. *arXiv preprint arXiv:1410.4627* (2014).
54. Cohn, D. A., Ghahramani, Z. & Jordan, M. I. Active learning with statistical models. *Journal of Artificial Intelligence Research* **4** (1996).
55. Kapoor, A., Grauman, K., Urtaşun, R. & Darrell, T. Active learning with gaussian processes for object categorization. In *IEEE ICCV* (2007).
56. Jain, P. & Kapoor, A. Active learning for large multi-class problems. In *IEEE CVPR* (2009).
57. Settles, B. Active learning literature survey. *University of Wisconsin, Madison* **52**, 11 (2010).
58. Kunapuli, G., Maclin, R. & Shavlik, J. W. Advice refinement in knowledge-based svms. In *NIPS* 1728–1736 (2011).
59. Deng, J., Krause, J., Stark, M. & Fei-Fei, L. Leveraging the wisdom of the crowd for fine-grained recognition. *IEEE T-PAMI* **38**, 666–676 (2016).
60. Ohki, K. & Reid, R. C. *In vivo* two-photon calcium imaging in the visual system. *Cold Spring Harbor Protocols* **2014**, pdb-prot081455 (2014).
61. Yao, B., Yang, X. & Zhu, S.-C. Introduction to a large-scale general purpose ground truth database: methodology, annotation tool and benchmarks. In *International Workshop on Energy Minimization Methods in Computer Vision and Pattern Recognition*, 169–183 (Springer, 2007).
62. University College, London, UK. Statistical parametric mapping (SPM) version 8. <http://www.fil.ion.ucl.ac.uk/spm/software/spm8/> (2009).
63. MathWorks. MATLAB, R2010a (2010).
64. Kay, K. N., David, S. V., Prenger, R. J., Hansen, K. A. & Gallant, J. L. Modeling low-frequency fluctuation and hemodynamic response timecourse in event-related fMRI. *Human brain mapping* **29**, 142–156 (2008).
65. Chang, C.-C. & Lin, C.-J. LIBSVM: A library for support vector machines. *ACM Transactions on Intelligent Systems and Technology* **2**, 27:1–27:27. Software available at <http://www.csie.ntu.edu.tw/~cjlin/libsvm/>. (2011).
66. Felzenszwalb, P. F. *et al.* Object detection with discriminatively trained part-based models. *IEEE T-PAMI* **32**, 1627–1645 (2010).
67. Evgeniou, T., Pontil, M. & Poggio, T. Regularization networks and support vector machines. In Smola, A., Bartlett, P. & Schölkopf, B. (eds.) *Advances in Large Margin Classifiers* (MIT Press, 2000).
68. Platt, J. Fast training of support vector machines using sequential minimal optimization. In *Advances in Kernel Methods - Support Vector Learning* 03/16/2017; 08/02/2017 (MIT Press, 1998).
69. cc0. photo. cc0. photo. <http://cc0.photo/> (2017).

Acknowledgements

The authors would like to thank J. Gallant and D. Stansbury for providing the fMRI data used in this study, as well as for helpful discussions regarding this work. This work was supported in part by NSF IIS Award #1409097, IARPA contract #D16PC00002, and an equipment donation from the NVIDIA Corporation. R.C.F. was supported in part by the Harvard College Research Program.

Author Contributions


R.C.F., W.J.S., and D.D.C. designed research and wrote the manuscript text; R.C.F. performed research and prepared all figures.

Additional Information

Supplementary information accompanies this paper at <https://doi.org/10.1038/s41598-018-23618-6>.

Competing Interests: The authors declare no competing interests.

Publisher's note: Springer Nature remains neutral with regard to jurisdictional claims in published maps and institutional affiliations.

	МИНОБРНАУКИ РОССИИ Федеральное государственное бюджетное образовательное учреждение высшего образования «Челябинский государственный университет» (ФГБОУ ВО «ЧелГУ»)		
	Миасский филиал Кафедра прикладной математики		
Фонд оценочных средств по дисциплине «Функциональное программирование» по направлению подготовки 01.03.02 Прикладная математика и информатика, профиль «Математическое моделирование» ФГБОУ ВО «ЧелГУ»			
Версия документа - 1	стр. 17 из 25	Первый экземпляр _____	КОПИЯ № _____

3.3. Критерии оценивания по видам оценочных средств

Критерии оценивания понимания текста:

“5” – «отлично» (96-100 баллов) «зачтено» – 100 – 75% понимания основного содержания текста, студент умеет свободно (почти свободно) и аргументировано высказываться, обстоятельно излагать содержание прочитанного, логически выстраивать свое сообщение, развивать отдельные положения и делать соответствующие выводы, изложение оформлено правильно грамматически и лексически.

“4” – «хорошо» (76-95 баллов) «зачтено» – 75% понимания основного содержания текста, студент может кратко излагать содержание прочитанного обосновать и объяснить свои взгляды, в изложении допускаются 2-3 незначимые грамматические или лексические ошибки.

“3” – «удовлетворительно» (60-75 балл) «зачтено» – 75 – 50% понимания основного содержания текста, студент может использовать простые фразы и предложения, но недостаточно понятно и обстоятельно излагать содержание прочитанного, в изложении 2-3 грамматические или лексические ошибки.

“2” – «неудовлетворительно» (0-60 балл) «не зачтено» – менее 50% понимания основного содержания текста, искажение содержания, превышение количества грамматических и лексических ошибок, студент владеет недостаточным словарным запасом, затрудняется в изложении прочитанного

Критерии оценивания теста


Оценка	Неудовлетворительно	Удовлетворительно	Хорошо	Отлично
Набранная сумма баллов (% выполненных заданий) (max – 100)	Менее 50	50-75	76-95	96-100
Оценка	Не зачтено	Зачтено		
Набранная сумма баллов (% выполненных заданий) (max – 100)	Менее 50	50-100		

Критерии оценивания контрольной работы

«отлично»

1) студент легко ориентируется в содержании учебного материала, свободно пользуется понятийным аппаратом, обладает умением связывать теорию с практикой, высказывать и обосновывать свои суждения;

1) знает и правильно применяет формулы;

	МИНОБРНАУКИ РОССИИ Федеральное государственное бюджетное образовательное учреждение высшего образования «Челябинский государственный университет» (ФГБОУ ВО «ЧелГУ»)		
	Миасский филиал Кафедра прикладной математики		
Фонд оценочных средств по дисциплине «Функциональное программирование» по направлению подготовки 01.03.02 Прикладная математика и информатика, профиль «Математическое моделирование» ФГБОУ ВО «ЧелГУ»			
Версия документа - 1	стр. 18 из 25	Первый экземпляр _____	КОПИЯ № _____

- 2) знает и правильно применяет нормативные документы;
- 3) решение задачи записано понятно, аккуратно, последовательно;
- 4) записан правильный ответ

«хорошо»

1) студент демонстрирует полное освоение теоретического материала, владеет понятийным аппаратом, ориентируется в изученном материале, осознанно применяет знания для решения практических задач, грамотно излагает свою позицию;

2) знает и применяет формулы и нормативные документы, но допускает небольшие неточности;

3) решение задачи записано, но не приведены формулы, с помощью которых были проведены расчеты;

4) записан правильный ответ

«удовлетворительно»

1) студент демонстрирует неполное освоение теоретического материала, плохо владеет понятийным аппаратом, плохо ориентируется в изученном материале, неуверенно излагает свою позицию;

2) знает отдельные формулы и нормативные документы, но допускает значительные неточности в их применении;

3) решение задачи записано неверно, но не приведены формулы, с помощью которых были проведены расчеты;

4) записан правильный ответ

«неудовлетворительно»

1) студент имеет разрозненные, бессистемные знания, не умеет выделять главное и второстепенное, допускает ошибки в определении понятий, искажающие их смысл;

2) беспорядочно и неуверенно излагает материал, не может применять знания для решения практических задач;

3) решение задачи записано неверно либо отсутствует;

4) записан неправильный ответ либо не записан ответ

4. ПОРЯДОК ПРОВЕДЕНИЯ И КРИТЕРИИ ОЦЕНИВАНИЯ ПРОМЕЖУТОЧНОЙ АТТЕСТАЦИИ

4.1. Порядок проведения и содержание оценочных средств промежуточной аттестации

К сдаче зачёта допускаются студенты, выполнившие самостоятельные работы в объёме не менее 50%.



МИНОБРНАУКИ РОССИИ
Федеральное государственное бюджетное образовательное
учреждение высшего образования
«Челябинский государственный университет» (ФГБОУ ВО «ЧелГУ»)
Миасский филиал
Кафедра прикладной математики

Фонд оценочных средств по дисциплине «Функциональное программирование»
по направлению подготовки 01.03.02 Прикладная математика и информатика, профиль «Математическое моделирование»
ФГБОУ ВО «ЧелГУ»

Версия документа - 1

стр. 19 из 25

Первый экземпляр _____

КОПИЯ № _____


Сдача зачёта проходит в компьютерном классе в виде теста с последующим устным ответом на 2 вопроса из списка вопросов к зачету.

Вопросы к зачёту

1. Концепция функционального программирования.
2. Требования к строго функциональному языку.
3. Функции в функциональном программировании.
4. S-выражения.
5. Списки как средство представления знаний.
6. Базовые функции Лиспа и их расширения.
7. Лямбда-исчисление как основа определения функций в Лиспе.
8. Описание тела функции в Лиспе. Функции и ветвление.
9. Неименованные функции Лиспа. Порядок вычисления лямбда-вызовов.
10. Именованные функции Лиспа и современная сокращенная нотация их представления.
11. Основные правила и примеры построения рекурсивных функций.
12. Основные и вспомогательные функции в программе на функциональном языке.
13. Нисходящее проектирование функциональных программ и его пример.
14. Восходящее проектирование функциональных программ и его пример.
15. Применение накапливающих параметров в функциональных программах. Примеры использования накапливающих параметров вспомогательными функциями.
16. Виды локальных определений. Рекурсивные локальные определения.
17. Данные и функции в функциональном программировании.
18. Функции высших порядков и их виды.
19. Применяющие функционалы и примеры их использования.
20. Редукция как функция высшего порядка.
21. Отображающие функционалы и примеры их использования.
22. Автофункции.
23. Структуры данных в концепции строго функционального языка.
24. Логическая и физическая структура списка в концепции виртуальной Лисп-машины.
25. Управление памятью и сборка мусора.
26. Точечная нотация.
27. Структуроразрушающие функции.
28. Макросы : назначение, отличительные особенности и этапы разработки. Тестирование макросов.



- 29.Использование макросов : реализация циклического предложения DO.
- 30.Использование макросов : реализация локального определения LET.
- 31.Деревья. Представление n-арных деревьев в памяти виртуальной Лисп-машины. Основные операции над деревьями : поиск, включение элемента в дерево, стяжение ветви.
- 32.Ассоциативные списки. Создание ассоциативного списка. Поиск элементов в ассоциативном списке. Поиск объекта по ключу. Добавление элементов в ассоциативный список. Модификация ассоциативных списков.
- 33.Применение ассоциативных списков для организации динамических баз данных(на примере машинного словаря основ).
- 34.Применение ассоциативных списков для решения задачи анализа конструкций формальных языков(на примере анализа и формулировки размерности математических формул).
- 35.Символы и списки свойств.
- 36.Управление потоками. Работа с файлами на внешних носителях.
- 37.Реализация динамических баз данных с применением списков свойств (на примере машинного словаря основ).
- 38.Представление знаний фреймами. Применение списков свойств для описания фреймовой структуры. Добавление и удаление фрейма из структуры. Управление выводом.
- 39.Представление знаний семантическими сетями. Наследование в семантических сетях. Расширение семантической сети. Процедурные семантические сети. Реализация семантической сети с помощью списков свойств символов. Вывод в семантической сети и его реализация на Лиспе.
- 40.Управляющие структуры и организация вычислений. Понятие формы.
- 41.Последовательные вычисления и их использование при описании моделей представления знаний (на примере фреймовых структур).
- 42.Организация вычислений в Лиспе : условные предложения и предложение выбора. Динамическое прекращение вычислений.
- 43.PROG-механизм и организация вычислений. Сравнительный анализ итеративного и рекурсивного программирования.
- 44.Лисп-системы и Лисп-машины. Перспективы функционального программирования.
45. Синтаксис и особенности языка функционального программирования Haskell. Стандартные классы Haskell и типы данных. Конструкторы типов и конструкторы данных.
46. Полиморфные типы и полиморфные функции с примерами применения. Типы, определяемые пользователем. Понятие и принцип действия механизма

	МИНОБРНАУКИ РОССИИ Федеральное государственное бюджетное образовательное учреждение высшего образования «Челябинский государственный университет» (ФГБОУ ВО «ЧелГУ») Миасский филиал Кафедра прикладной математики		
	Фонд оценочных средств по дисциплине «Функциональное программирование» по направлению подготовки 01.03.02 Прикладная математика и информатика, профиль «Математическое моделирование» ФГБОУ ВО «ЧелГУ»		
Версия документа - 1	стр. 21 из 25	Первый экземпляр _____	КОПИЯ № _____

pattern-matching (соответствия образцу). Функции как объекты первого класса (first-class objects). Сигнатура типа функции. Понятие каррированных и некаррированных функций. Инфиксные операторы. Синонимы типов как средство повышения читабельности функциональных программ.

47. Генераторы. Лямбда-абстракции в Haskell. Функции высших порядков в Haskell.

48. Отложенные вычисления. Механизмы организации массивов в Haskell и простейшие примеры их обработки. Примеры организации более сложных программ. Представление и интерпретация функциональных программ.

49. Абстрактная и конкретная формы программ.

50. Проблема связывания значений и переменных. Техника интерпретации функциональных программ.

51. Соответствие между функциональными и императивными программами. Особенности интерпретирования императивных программ. Функциональные эквиваленты императивных программ. Преобразование императивных программ в функциональные.

52. Аппаратное обеспечение функциональных программ. Функциональный подход к параллелизму. Задержка вычислений. Замедленные вычисления. 53. Сети связанных процессов. Функции высших порядков. Типы функций и понятие высшего порядка функции.

53. Композиция функций. Примеры применения функций высшего порядка

Пример вопросов для теста

Примеры вопросов для теста:

1. Какая функция имеет сигнатуру $((a \rightarrow b \rightarrow a) \rightarrow a \rightarrow b \text{ list} \rightarrow a)$
 - a. List.map
 - b. List.fold
 - c. List.zip
 - d. List.unzip

2. ООП парадигма отличается от других
 - a. отсутствием побочных эффектов у функций
 - b. декомпозицией решения на несколько шагов
 - c. изменением некоторого глобального состояния
 - d. объединением данных и логики в объекты



3. Является ли корректным утверждение 'операторы в языке F# вызываются в инфиксном стиле'

- a. Верно
- b. Неверно

4. Какая функция имеет сигнатуру $((a \rightarrow b \rightarrow 'a) \rightarrow 'a \rightarrow 'b \text{ list} \rightarrow 'a)$

- a. List.map
- b. List.fold
- c. List.zip
- d. List.unzip

5. ООП парадигма отличается от других

- a. отсутствием побочных эффектов у функций
- b. декомпозицией решения на несколько шагов
- c. изменением некоторого глобального состояния
- d. объединением данных и логики в объекты

6. Является ли корректным утверждение 'операторы в языке F# вызываются в инфиксном стиле'

- a. Верно
- b. Неверно

4.2. Критерии оценивания компетенций в ходе промежуточной аттестации

Код компетенции	Планируемые результаты обучения по дисциплине	Критерии оценивания	
		Зачтено	Не зачтено
УК-4	Знает: терминологию предметной области на английском языке	Знает: терминологию предметной области на английском языке	Не знает: терминологию предметной области на английском языке
	Умеет: переводить на русский язык документацию программ на английском языке;	Умеет: переводить на русский язык документацию программ на английском языке;	Не умеет: переводить на русский язык документацию программ на английском языке;



МИНОБРНАУКИ РОССИИ
Федеральное государственное бюджетное образовательное
учреждение высшего образования
«Челябинский государственный университет» (ФГБОУ ВО «ЧелГУ»)
Миасский филиал
Кафедра прикладной математики

Фонд оценочных средств по дисциплине «Функциональное программирование»
по направлению подготовки 01.03.02 Прикладная математика и информатика, профиль «Математическое моделирование»
ФГБОУ ВО «ЧелГУ»

Версия документа - 1

стр. 23 из 25

Первый экземпляр _____

КОПИЯ № _____

	Владеет: навыками чтения и понимания документации программ на английском языке;	Владеет: навыками чтения и понимания документации программ на английском языке;	Не владеет: навыками чтения и понимания документации программ на английском языке;
ПК-2	Знает: основные методы разработки интеллектуальных систем, ключевые термины в области искусственного интеллекта и интеллектуальных систем	Знает: основные методы разработки интеллектуальных систем, ключевые термины в области искусственного интеллекта и интеллектуальных систем	Не знает: основные методы разработки интеллектуальных систем, ключевые термины в области искусственного интеллекта и интеллектуальных систем
	Умеет: использовать существующие библиотеки и инструментальные средства для разработки интеллектуальных систем	Умеет: использовать существующие библиотеки и инструментальные средства для разработки интеллектуальных систем	Не умеет: использовать существующие библиотеки и инструментальные средства для разработки интеллектуальных систем
	Владеет: навыками проектирования интеллектуальных систем, навыками анализа и моделирования предметной области	Владеет: навыками проектирования интеллектуальных систем, навыками анализа и моделирования предметной области	Не владеет: навыками проектирования интеллектуальных систем, навыками анализа и моделирования предметной области

4.3. Критерии оценивания зачета

Критерии оценивания ответа студента на зачёте:

Письменный и письменно-устный ответ студента по вопросам дисциплины оценивается положительно с выставлением оценки «зачтено» в следующих случаях:

– студент глубоко и полно владеет содержанием учебного материала; умеет связывать теорию с практикой, решает соответствующие задачи, теоретические выводы подтверждает примерами. Делает выводы логично, четко. Ясно и кратко излагает ответы на поставленные вопросы; умеет обосновывать свои суждения. Дан полный, развернутый ответ на поставленный вопрос; показана совокупность осознанных знаний об объекте изучения, утверждения теорем приведены с доказательствами, свободно оперирует понятиями, терминами; в ответе прослеживается четкая структура,



выстроенная в логической последовательности; ответ изложен литературным грамотным языком и носит самостоятельный характер; все решения задач выполнены верно.

– ответ студента соответствует указанным выше критериям, но содержание ответа имеет отдельные неточности (несущественные ошибки) в изложении теоретического и практического материала, отличается меньшей обстоятельностью, глубиной, обоснованностью и полнотой; были допущены неточности в определении понятий, допущены незначительные ошибки в решении задач, допущенные ошибки исправляются студентом после дополнительных вопросов экзаменатора.

– студент обнаруживает знание и понимание основных положений учебного материала, но излагает его неполно, непоследовательно, допускает неточности и существенные ошибки в определении понятий, формулировке положений, наблюдается нарушение логики изложения; в ответе не присутствуют доказательные выводы; сформированность умений показана слабо, допущены незначительные ошибки в решении задач.

Оценка «не зачтено» за письменный и письменно-устный ответ студента по вопросам дисциплины выставляется в случаях, когда:

– студент имеет разрозненные, бессистемные знания: не умеет выделять главное и второстепенное; допускает ошибки в определении понятий, формулировке теоретических положений, искажает их смысл; беспорядочно и неуверенно излагает материал;

– не умеет соединять теоретические положения с практикой; не умеет применять знания для обоснования и объяснения фактов, не устанавливает межпредметные связи.

4.4. Результаты промежуточной аттестации и уровни сформированности компетенций

Уровень освоения компетенций	Оценка
Продвинутый	зачтено
Базовый	зачтено
Пороговый	зачтено
компетенции не сформированы	не зачтено

Уровни формирования компетенций:

1. Пороговый уровень:



МИНОБРНАУКИ РОССИИ
Федеральное государственное бюджетное образовательное
учреждение высшего образования
«Челябинский государственный университет» (ФГБОУ ВО «ЧелГУ»)
Миасский филиал
Кафедра прикладной математики

Фонд оценочных средств по дисциплине «Функциональное программирование»
по направлению подготовки 01.03.02 Прикладная математика и информатика, профиль «Математическое моделирование»
ФГБОУ ВО «ЧелГУ»

Версия документа - 1

стр. 25 из 25

Первый экземпляр _____

КОПИЯ № _____

- предполагает формирование компетенций на начальном уровне: знание основ функционального программирования;
- студент способен давать ответы на теоретические вопросы дисциплины на удовлетворительном уровне.

2. Базовый уровень:

- предполагает формирование компетенций на более высоком уровне: формируется комплексное знание особенностей и применения методов функционального программирования;
- студент способен давать развернутые ответы на теоретические вопросы дисциплины; способен решать практические задания.

3. Продвинутый уровень:

- предполагает формирование компетенций на высоком уровне, использует полученные знания и умения при изучении смежных дисциплин, обнаруживает готовность к самостоятельной профессиональной деятельности;
- студент способен аргументировать собственную точку зрения, формулировать собственные выводы на основе применения усвоенных компетенций.