


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:  
891934b8c2cf7b6350cbe51c4b3096e877f6167



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 «Компьютерная автоматизация эксперимента» 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

***Компьютерная автоматизация эксперимента***

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,  
Компьютерная автоматизация эксперимента, 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)

Р.Е. Молодцов

**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 «Компьютерная автоматизация эксперимента»  
по направлению подготовки 01.03.02 Прикладная математика и информатика, профиль «Математическое моделирование»  
ФГБОУ ВО «ЧелГУ»

Версия документа - 1

стр. 3 из 24

Первый экземпляр \_\_\_\_\_

КОПИЯ № \_\_\_\_\_

## 1. ПАСПОРТ ФОНДА ОЦЕНОЧНЫХ СРЕДСТВ

Направление подготовки: 01.03.02 Прикладная математика и информатика

Направленность (профиль): Математическое моделирование

Дисциплина: Компьютерная автоматизация эксперимента (научный семинар)

Семестры изучения: 7

Форма промежуточной аттестации: зачет

## 2. ПЕРЕЧЕНЬ ФОРМИРУЕМЫХ КОМПЕТЕНЦИЙ

### 2.1. Компетенции, закреплённые за дисциплиной

Изучение дисциплины «Компьютерная автоматизация эксперимента» 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
1	2	3	4
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)	Знать основные термины дисциплины на английском языке. Уметь читать техническую документацию на английском языке. Владеть навыками использования технической документации на английском языке.
ПК-1	Способен к работе прочностных, аэродинамических, теплофизических	ПК-1.1. Имеет представление о современных методах проведения расчетов параметров нагружения	Знать основы схмотехники функциональных устройств автоматизированных систем, основы схмотехники циф-



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 «Компьютерная автоматизация эксперимента»  
по направлению подготовки 01.03.02 Прикладная математика и информатика, профиль «Математическое моделирование»  
ФГБОУ ВО «ЧелГУ»

Версия документа - 1

стр. 4 из 24

Первый экземпляр \_\_\_\_\_

КОПИЯ № \_\_\_\_\_

характеристик изделий РКТ на основе современных пакетов прикладных программ, к математическому моделированию в области динамики, баллистики и управления полетом на базе современных компьютерных технологий	конструкций изделий, включая метод конечных элементов, основах теории теплопередачи, радиационного теплообмена, современных методах обработки данных, математических методах проведения баллистических расчетов, основах аэродинамики, методах проектирования ракет. ПК-1.2. Демонстрирует умение применять современные системы автоматизированного проектирования (САПР), в том числе: пакеты прикладных программ конечно-элементного анализа; пакеты прикладных программ для обработки экспериментальных данных, автоматизации эксперимента. ПК-1.3. Имеет практический опыт математического моделирования и применения пакетов прикладных программ для решения задач аэрогазодинамики, тепловой защиты, прочности, динамики движения в области РКТ.	ро- аналоговых преобразователей; Принципы работы датчиков для измерения механических величин. Способы использования компьютера для управления ходом эксперимента. Общие принципы и требования, предъявляемые к автоматизированным системам. - Составные компоненты автоматизированных исследовательских систем. <i>Уметь</i> применять принципы преобразования различных физических величин в цифровую форму. Применять измерительные датчики, цифро-аналоговые и аналогово-цифровые преобразователи <i>Владеть</i> навыками применения измерительных датчиков, цифро-аналоговых и аналогово-цифровых преобразователей; Навыками практической реализации автоматизированной системы исследований. Навыками подключения к компьютеру периферийных устройств и его коммуникации с другими компьютерами, используя параллельный и последовательный интерфейсы соединений.
--	--	---

### 3. СОДЕРЖАНИЕ ОЦЕНОЧНЫХ СРЕДСТВ ПО ДИСЦИПЛИНЕ

#### 3.1 Виды оценочных средств

№п/п	Контролируемые темы/разделы	Код компетенции/ планируемые результаты обучения	Наименование оценочно	Наименование оценочного
------	-----------------------------	---	--------------------------	----------------------------



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 «Компьютерная автоматизация эксперимента»  
по направлению подготовки 01.03.02 Прикладная математика и информатика, профиль «Математическое моделирование»  
ФГБОУ ВО «ЧелГУ»

Версия документа - 1

стр. 5 из 24

Первый экземпляр \_\_\_\_\_

КОПИЯ № \_\_\_\_\_

			го средства для текущего контроля	средства на промежуточной аттестации
1	Основы схемотехники функциональных устройств автоматизированных систем	ПК-1 Знает способы использования компьютера для управления ходом эксперимента, структуру адресации в процессорных устройствах; Умеет работать с двоичным форматом машинного исчисления, работать с интерфейсными устройствами соединения блоков автоматизированных систем; Владеет методами практической реализации автоматизированной системы исследований. УК-4 Знает основные термины дисциплины на английском языке	Практическая работа №1, Вопросы для собеседования Перевод англоязычных научных статей	Вопросы к зачету.
2	Принципы работы датчиков для измерения механических величин	ПК-1 Знает виды датчиков и их классификацию, виды преобразований физических явлений, понятия термоэлектричества и термопары; Умеет по виду датчика понимать его тип и назначение, получать информацию с любого датчика в виде, понятном пользователю; Владеет методами считывания данных после отработки системы. УК-4 Умеет читать техническую документацию на английском языке.	Практическая работа №2 Вопросы для собеседования Перевод англоязычных научных статей	Вопросы к зачету.
3	Основы схемотехники цифро-аналоговых преобразователей	ПК-1 Знает классификацию преобразователей по типам, функциональные устройства на операционных усилителях для выполнения математических операций; Умеет восстанавливать исходный сигнал, высчитывать погрешность сигнала;	Практическая работа №3 Вопросы для собеседования Перевод англоязычных	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 «Компьютерная автоматизация эксперимента»  
по направлению подготовки 01.03.02 Прикладная математика и информатика, профиль «Математическое моделирование»  
ФГБОУ ВО «ЧелГУ»

Версия документа - 1

стр. 6 из 24

Первый экземпляр \_\_\_\_\_

КОПИЯ № \_\_\_\_\_

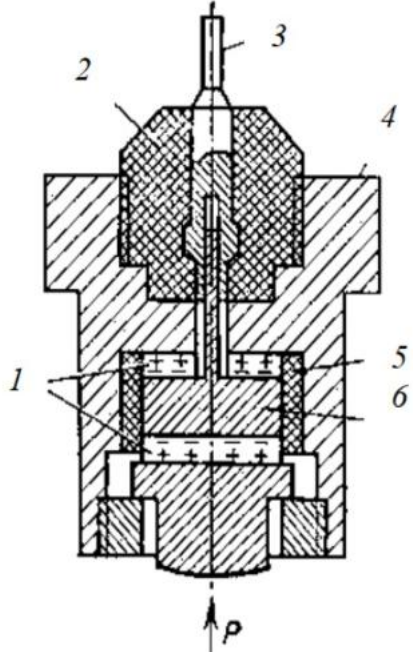
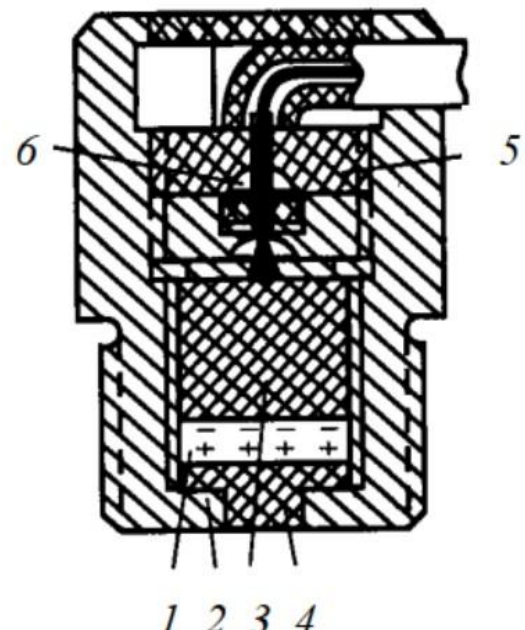
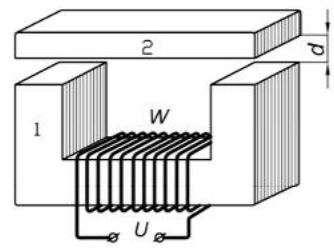
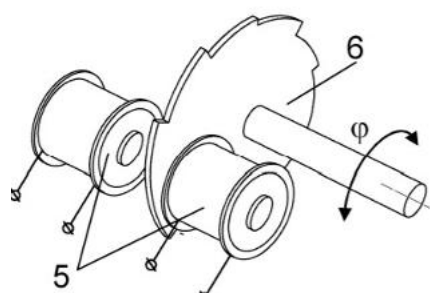
		Владеет навыками подключения последовательных шин методом «огненного провода», навыками подключения параллельных шин, логическим преобразованием в приоритетном шифраторе преобразователя. УК-4 Владеет навыками использования технической документации на английском языке.	ных научных статей	
--	--	--	--------------------	--

Типовые задания, контрольные работы, тесты критерии и показатели оценивания в рамках текущего контроля представлены в рабочей программе по дисциплине. Полные комплекты оценочных средств и контрольно-измерительных материалов хранятся на кафедре и являются учебно-методическими материалами ограниченного (конфиденциального) пользования.

### 3.2 Содержание оценочных средств для текущей аттестации Практическая работа №1


Номер	Вариант 1	Вариант 2
1	Какие бывают контактные термометры? Ответ: термопары, термометр сопротивления, манометрические термометры, термометры расширения	Какие бывают бесконтактные термометры? Ответ: пирометры, радиометры, тепловизоры
2	По рисунку определить вид датчика	По рисунку определить вид датчика



	 <p>Ответ: пьезодатчик давления</p>	 <p>Ответ: пьезодатчик ускорения</p>
3	<p>По виду датчика определить его вид:</p>  <p>Ответ: Индуктивный датчик с переменным зазором</p>	<p>По виду датчика определить его вид:</p>  <p>Ответ: Индуктивный датчик с профильным магнитным экраном</p>
4	<p>Датчик СЕЛЬСИН питается током частотой 400 Гц и использует трансформаторную систему включения. Какое напряжение необходимо подать, если используется 2 обмотки стартера? Ответ: 36 вольт</p>	<p>Датчик СЕЛЬСИН питается током частотой 1000 Гц и использует трансформаторную систему включения. Какое напряжение необходимо подать, если используется 2 обмотки стартера? Ответ: 110 вольт</p>

### Вопросы для собеседования:

1. Для каких целей используются аналого-цифровые и цифро-аналоговые преобразователи сигналов? Какова их роль в современных электронных устройствах? Перечислите основные этапы обработки аналоговых сигналов цифровыми методами и поясните их суть.
2. Поясните сущность и общие принципы цифро-аналогового и аналого-цифрового преобразований. Какие базовые узлы используются при построении преобразователей? На

	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 «Компьютерная автоматизация эксперимента» по направлению подготовки 01.03.02 Прикладная математика и информатика, профиль «Математическое моделирование» ФГБОУ ВО «ЧелГУ»		
Версия документа - 1	стр. 8 из 24	Первый экземпляр _____	КОПИЯ № _____

чем базируется цифро-аналоговое преобразование? Какие основные операции выполняются при аналого-цифровом преобразовании? В чем состоит недостаток их совмещения? Какие способы используют для аналого-цифрового преобразования и в чем их сущность?

3. Перечислите основные классификационные признаки ЦАП и АЦП. Какие характерные признаки имеют ЦАП и АЦП?

4. На какие группы можно разбить технические показатели ЦАП и АЦП?

5. Назовите основные статические и динамические показатели преобразователей. Поясните, какие качества преобразователей они характеризуют.

6. Перечислите основные типы параллельных ЦАП с суммированием эталонных напряжений и токов. Каковы их особенности? Поясните принцип построения схемы и работы каждого из преобразователей.

7. На каком принципе строят ЦАП последовательного типа? Поясните принцип построения и функционирования ЦАП с ШИМ.

8. Какие базовые элементы используются в ЦАП на переключаемых конденсаторах? Приведите схемы 4-разрядных ЦАП с матрицей конденсаторов и поясните принцип их работы. Как строится и работает сигма-дельта ЦАП? В чем состоят особенности преобразователей на переключаемых конденсаторах по сравнению с классическими ЦАП?

9. Что такое сегментация? Как осуществляется сегментирование с использованием строковых ЦАП? Поясните принцип построения и работы сегментированных ЦАП с токовым выходом и с использованием преобразователя на переключаемых конденсаторах.

10. Перечислите основные типы быстродействующих АЦП. Каковы недостатки параллельных АЦП? С помощью каких средств достигается упрощение АЦП при небольшой потере быстродействия? Поясните принцип построения и работы двух ступенчатых и конвейерных АЦП.

11. Перечислите основные типы последовательных АЦП и дайте их краткую характеристику. Поясните принцип построения и работы АЦП на переключаемых конденсаторах, АЦП с двойным интегрированием, АЦП ускоренного интегрирования, АЦП последовательного приближения, многоступенчатых АЦП последовательного счета.

12. Что служит основой для построения сигма-дельта АЦП? Поясните принципы модуляции. Какие средства используют для повышения качества преобразования?

## **Англоязычные научные статьи для перевода**



# SCIENTIFIC REPORTS

OPEN

## Using human brain activity to guide machine learning

Ruth C. Fong<sup>1,3</sup>, Walter J. Scheirer<sup>2,3</sup> & David D. Cox<sup>3</sup>

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<sup>1–3</sup>. 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<sup>4–7</sup>. Moreover, the patterns of errors made by today’s algorithms differ dramatically from those of humans performing the same tasks<sup>8,9</sup>, 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<sup>10–12</sup>. 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<sup>13–15</sup>, and strategies for decision making that incorporate cognitive models of Bayesian reasoning<sup>16</sup> and exemplar learning<sup>17</sup> 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<sup>18–21</sup>, neural response prediction<sup>22–26</sup>, and hierarchical modeling<sup>27–29</sup>. Concurrently, machine learning algorithms are also leveraging biological concepts like working memory<sup>30</sup>, experience replay<sup>31</sup>, and attention<sup>32,33</sup> and are being encouraged to borrow more insights from the inner workings of the human brain<sup>34</sup>. 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 behavior<sup>35</sup>, and one work introduced a method to determine a mapping from images to “brain-like” features extracted from EEG recordings<sup>36</sup>. Furthermore, recent advances in machine learning have focused on improving feature representation, often in a biologically-consistent way<sup>38</sup>, 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

<sup>1</sup>Department of Engineering Science, University of Oxford, Information Engineering Building, Oxford, OX1 3PJ, United Kingdom. <sup>2</sup>Department of Computer Science and Engineering, University of Notre Dame, Fitzpatrick Hall of Engineering, Notre Dame, IN, 46556, USA. <sup>3</sup>Department 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<sup>8,37</sup>, 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) features<sup>38</sup> and 2., convolutional neural network (CNN) features (i.e., 1000-dimensional, pre-softmax activations from AlexNet<sup>13</sup> pre-trained on the ImageNet dataset<sup>1</sup>). HOG features were the standard, off-the-shelf image feature representation before the 2012 advent of powerful CNNs<sup>1</sup>, while CNNs pre-trained on large datasets like ImageNet are known to be strong, general image features, which can transfer well to other tasks<sup>39,40</sup>. 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 Berkeley<sup>41</sup>. 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<sup>42,43</sup> and colors and shapes in V4<sup>44,45</sup>): 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) models<sup>46</sup>:

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

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 it<sup>47</sup>. 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:

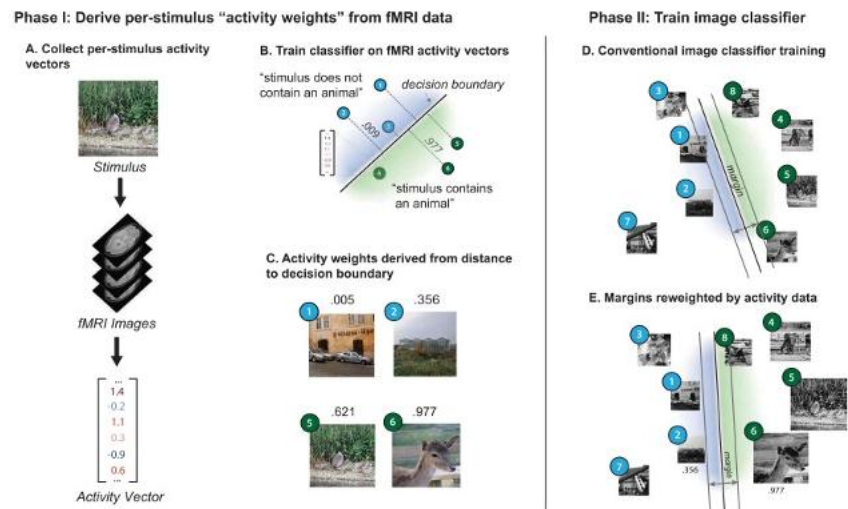
$$\phi_c(x, z) = \max(0, (1 - z) \cdot M(x, z)) \quad (2)$$

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



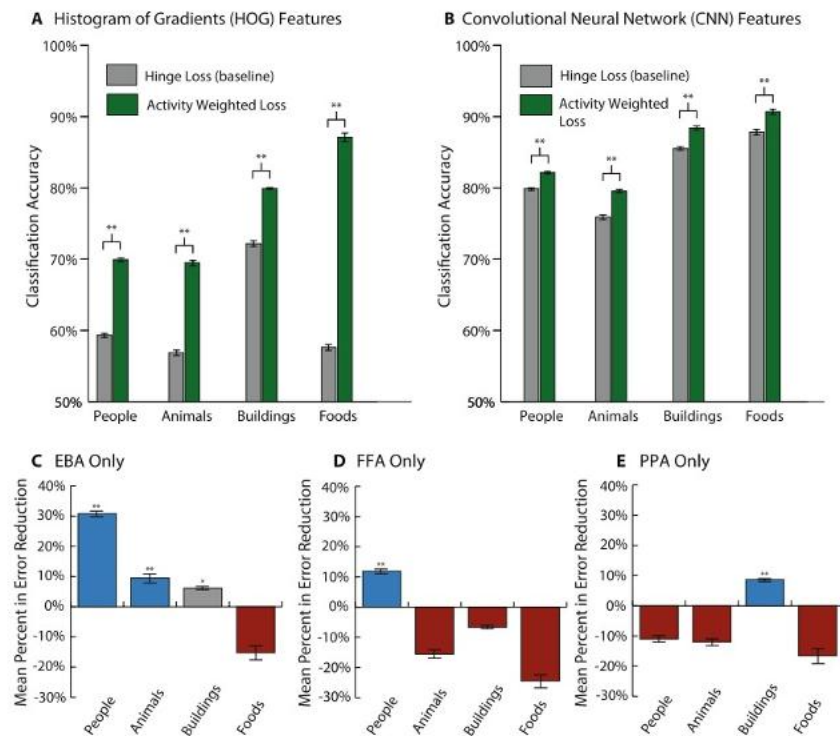
**Figure 1.** Experimental workflow for biologically-informed machine learning using fMRI data. (A) fMRI was used to record BOLD voxel responses of one subject viewing 1,386 color images of natural scenes, providing labelled voxels in several conventional, functional ROIs (i.e., EBA, FFA, LO, OFA, PPA, RSC, and TOS)<sup>41</sup>. (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 function<sup>48</sup>. (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 from<sup>69</sup> 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 work<sup>8</sup>, 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.,  $f_j: X_j \rightarrow [0,1]$ , trained on the training voxel data for the combination into probabilities via a logistic transformation<sup>48</sup> (Fig. 1A–C).  $x_{j(i)} \in X_j$  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  $x_p$ , and the resulting probability  $c_{x_i} = f_j(x_{j(i)})$  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<sup>38,49</sup>; CNNs are learned feature representations that

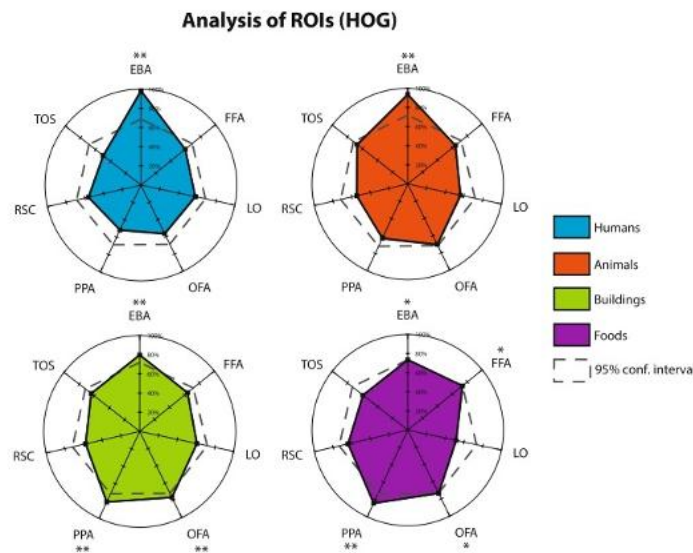


**Figure 2.** Results showing the effect of conditioning classification models for four visual classes on fMRI data during supervised training (Fig. 1). (A,B) Side-by-side comparisons of the mean classification accuracy between models that were trained using either (A) HOG features or (B) CNN features 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<sup>14,22</sup>.  $x_{HOG} \in X_H$  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<sup>50–52</sup>. 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 an 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.



## 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 algorithms<sup>53</sup>. However, while measures of human behavior have been used extensively to guide machine learning via active learning<sup>54–57</sup>, structured domain knowledge<sup>58</sup>, and discriminative feature identification<sup>59</sup>, 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 imaging<sup>60</sup>. 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 brain<sup>24</sup>.

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 categorization<sup>41</sup>. 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 =  $104 \times 104$ ; TR = 2,009.9 ms; TE = 35 ms; flip angle =  $74^\circ$ ; voxel size =  $2.25 \times 2.25 \times 2.99 \text{ mm}^3$ ). While<sup>41</sup> 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  $\times$  500 color images of natural scenes from<sup>41,61</sup>, which the subject viewed while his brain activity was being recorded (see<sup>41</sup> 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



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 «Компьютерная автоматизация эксперимента»  
по направлению подготовки 01.03.02 Прикладная математика и информатика, профиль «Математическое моделирование»  
ФГБОУ ВО «ЧелГУ»

Версия документа - 1

стр. 15 из 24

Первый экземпляр \_\_\_\_\_

КОПИЯ № \_\_\_\_\_

[www.nature.com/scientificreports/](http://www.nature.com/scientificreports/)

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 package<sup>62</sup> was used. Custom MATLAB<sup>63</sup> 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 function<sup>64</sup>. See Stansbury *et al.*<sup>51</sup> 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  $i$ ,  $\vec{x}_i$  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  $i$ .

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

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 transformation<sup>65</sup> 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  $\gamma$  for an RBF SVM classifier using the LibSVM package<sup>65</sup>. Finally, activity weights were generated by testing the classifier on the held-out fold to produce Platt probability scores<sup>48</sup> 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  $500 \times 500$  colored images were down sampled to  $250 \times 250$  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` function<sup>49</sup>, which computes UoCTTI HOG features<sup>66</sup>. Convolutional neural network (CNN) features were generated using the Caffe library's BLVC Reference CaffeNet model<sup>14</sup>, which is AlexNet trained on ILSVRC 2012<sup>1</sup>, with minor differences from the version described by Krizhevsky *et al.*<sup>13</sup>. 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) function<sup>67</sup> and another that uses a 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 Optimization<sup>68</sup>. 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 function<sup>65</sup>. To train classifiers using an activity weighted loss function, we modified publicly available code for an alternative additive loss formulation<sup>8</sup>.

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.*<sup>41</sup> 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., Sibite, 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., Urtasun, 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 «Компьютерная автоматизация эксперимента» по направлению подготовки 01.03.02 Прикладная математика и информатика, профиль «Математическое моделирование» ФГБОУ ВО «ЧелГУ»		
Версия документа - 1	стр. 18 из 24	Первый экземпляр _____	КОПИЯ № _____

### 3.3. Критерии оценивания по видам оценочных средств

#### Критерии оценивания решения практических заданий

«зачтено»

- 1) Работа представлена в установленный срок и оформлена в соответствии с установленными требованиями
- 2) Работа написана самостоятельно и в ней в полной мере раскрыты вопросы контрольных заданий
- 3) Используются специальные источники (нормативно-законодательные акты и литература)
- 4) работа содержит правильную формулировку понятий и категорий
- 5) в освещении вопросов заданий не содержится грубых ошибок
- 6) при решении заданий сделаны правильные и аргументированные выводы

«не зачтено»

- 1) студент не справился с заданиями
- 2) в работе не раскрыто основное содержание вопросов, имеются грубые ошибки
- 3) имеются явные признаки плагиата
- 4) оформление работы не соответствует требованиям

Работа, по результатам проверки которой выставлена оценка «не зачтено», возвращается студенту на доработку. Студент не может быть допущен до сдачи зачета до тех пор, пока не представит исправленную работу.

#### Критерии оценки собеседования

«отлично»

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

«хорошо»

- 1) студент демонстрирует полное освоение теоретического материала, владеет понятийным аппаратом, ориентируется в изученном материале, грамотно излагает свою позицию

«удовлетворительно»



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 «Компьютерная автоматизация эксперимента»  
по направлению подготовки 01.03.02 Прикладная математика и информатика, профиль «Математическое моделирование»  
ФГБОУ ВО «ЧелГУ»

Версия документа - 1

стр. 19 из 24

Первый экземпляр \_\_\_\_\_

КОПИЯ № \_\_\_\_\_

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

### **Критерии оценивания перевода статьи:**

“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) «незачтено» – менее 50% понимания основного содержания текста, искажение содержания, превышение количества грамматических и лексических ошибок, студент владеет недостаточным словарным запасом, затрудняется в изложении прочитанного.

## **4. ПОРЯДОК ПРОВЕДЕНИЯ И КРИТЕРИИ ОЦЕНИВАНИЯ ПРОМЕЖУТОЧНОЙ АТТЕСТАЦИИ**

### **4.1. Порядок проведения и содержание оценочных средств промежуточной аттестации**

**Зачет** проводится в форме письменно-устного опроса. На письменный ответ студента отводится 40 минут, затем ответ проверяется преподавателем, при необходимости могут быть заданы уточняющие вопросы.

	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 «Компьютерная автоматизация эксперимента» по направлению подготовки 01.03.02 Прикладная математика и информатика, профиль «Математическое моделирование» ФГБОУ ВО «ЧелГУ»		
Версия документа - 1	стр. 20 из 24	Первый экземпляр _____	КОПИЯ № _____

## Вопросы для зачета

1. Основные принципы работы первичных преобразователей (датчиков), применяемых при гидроаэрогазодинамических исследованиях (тензорезистивный эффект, пьезоэлектрический эффект, эффект измерения электрической ёмкости, электромагнитные явления).
2. Способы измерения давлений при гидроаэрогазодинамических исследованиях в потоке жидкости или газа, на поверхности тел вращения.
3. Способы измерения скоростей потока жидкости или газа при гидроаэродинамических исследованиях (малые скорости, большие скорости).
4. Методы оценки суммарной погрешности экспериментального определения гидроаэрогазодинамических характеристик.
5. Автоматизированные системы обработки экспериментальных данных на гидроаэрогазодинамических стендах ГРЦ.
6. Общие принципы и задачи автоматизации.
7. Структура автоматизированной системы.
8. Системы счисления.
9. Преобразователи физических явлений. Активные и пассивные измерительные датчики.
10. Электромеханические датчики (смещения, деформации, силы, давления, потока, акселерометры, пространственного положения).
11. Пьезоэлектрические датчики (пьезокерамические датчики, пьезоприводы, пьезокерамические преобразователи).
12. Термоэлектрические датчики (термопарные датчики температуры, резистивные и полупроводниковые датчики, пирометрия).
13. Оптические датчики. Датчики изображения. ССD линейка и матрица.
14. Операционный усилитель. Функциональные устройства на операционных усилителях. Частотные электрические фильтры.
15. Принципы построения изолированных измерительных усилителей.
16. Цифро-аналоговые преобразователи (ЦАП).
17. Параллельные ЦАП.
18. Последовательные ЦАП.
19. Аналого-цифровые преобразователи (АЦП).
20. Параллельные АЦП.
21. Последовательно-параллельные АЦП.
22. Последовательные АЦП.



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 «Компьютерная автоматизация эксперимента»  
по направлению подготовки 01.03.02 Прикладная математика и информатика, профиль «Математическое моделирование»  
ФГБОУ ВО «ЧелГУ»

Версия документа - 1

стр. 21 из 24

Первый экземпляр \_\_\_\_\_

КОПИЯ № \_\_\_\_\_

23. Оптические датчики положения.
24. Принципы построения изолированных измерительных усилителей.
25. Частотные электрические фильтры.
26. Виды интерфейсов.
27. Типы интерфейсного обмена (синхронный, асинхронный, изохронный).
28. Параллельный LPT-порт (характеристики).
29. Последовательный COM-порт (характеристики).
30. Порт последовательная шина USB (характеристики).

#### 4.2. Критерии оценивания компетенций в ходе промежуточной аттестации

Код компетенции	Планируемые результаты обучения по дисциплине	Критерии оценивания	
		зачтено	не зачтено
УК-4	Знает основные термины дисциплины на английском языке.	Знает основные термины дисциплины на английском языке.	Не знает основные термины дисциплины на английском языке.
	Умеет читать техническую документацию на английском языке.	Умеет читать техническую документацию на английском языке.	Не умеет читать техническую документацию на английском языке.
	Владеет навыками использования технической документации на английском языке.	Владеет навыками использования технической документации на английском языке.	Не владеет навыками использования технической документации на английском языке.
ПК-1	<i>Знает</i> основы схемотехники функциональных устройств автоматизированных систем, основы схемотехники цифро-аналоговых преобразователей; Принципы работы датчиков для измерения механических величин. Способы использования компьютера для управления ходом эксперимента. Общие принципы и требования, предъявляемые к автоматизированным системам. - Составные компоненты автоматизи-	<i>Знает</i> основы схемотехники функциональных устройств автоматизированных систем, основы схемотехники цифро-аналоговых преобразователей; Принципы работы датчиков для измерения механических величин. Способы использования компьютера для управления ходом эксперимента. Общие принципы и требования, предъявляемые к автоматизированным системам. - Составные компоненты автоматизи-	<i>Не знает</i> основы схемотехники функциональных устройств автоматизированных систем, основы схемотехники цифро-аналоговых преобразователей; Принципы работы датчиков для измерения механических величин. Способы использования компьютера для управления ходом эксперимента. Общие принципы и требования, предъявляемые к автоматизированным системам. - Составные компоненты



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 «Компьютерная автоматизация эксперимента»  
по направлению подготовки 01.03.02 Прикладная математика и информатика, профиль «Математическое моделирование»  
ФГБОУ ВО «ЧелГУ»

Версия документа - 1

стр. 22 из 24

Первый экземпляр \_\_\_\_\_


КОПИЯ № \_\_\_\_\_

рованных исследовательских систем.	зированных исследовательских систем.	автоматизированных исследовательских систем.
<i>Умеет</i> применять принципы преобразования различных физических величин в цифровую форму. Применять измерительные датчики, цифро-аналоговые и аналогово-цифровые преобразователи	<i>Умеет</i> применять принципы преобразования различных физических величин в цифровую форму. Применять измерительные датчики, цифро-аналоговые и аналогово-цифровые преобразователи	<i>Не умеет</i> применять принципы преобразования различных физических величин в цифровую форму. Применять измерительные датчики, цифро-аналоговые и аналогово-цифровые преобразователи
<i>Владеет</i> навыками применения измерительных датчиков, цифро-аналоговых и аналогово-цифровых преобразователей; Навыками практической реализации автоматизированной системы исследований. Навыками подключения к компьютеру периферийных устройств и его коммуникации с другими компьютерами, используя параллельный и последовательный интерфейсы соединений.	<i>Владеет</i> навыками применения измерительных датчиков, цифро-аналоговых и аналогово-цифровых преобразователей; <b>Навыками практической реализации автоматизированной системы исследований. Навыками подключения к компьютеру периферийных устройств и его коммуникации с другими компьютерами, используя параллельный и последовательный интерфейсы соединений.</b>	<i>Не владеет</i> навыками применения измерительных датчиков, цифро-аналоговых и аналогово-цифровых преобразователей; Навыками практической реализации автоматизированной системы исследований. Навыками подключения к компьютеру периферийных устройств и его коммуникации с другими компьютерами, используя параллельный и последовательный интерфейсы соединений.

### 4.3. Критерии оценивания зачета

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

	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 «Компьютерная автоматизация эксперимента» по направлению подготовки 01.03.02 Прикладная математика и информатика, профиль «Математическое моделирование» ФГБОУ ВО «ЧелГУ»		
Версия документа - 1	стр. 23 из 24	Первый экземпляр _____	КОПИЯ № _____

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:**

- предполагает формирование компетенций на начальном уровне: знание объекта, предмета, цели, задач преобразования различных



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 «Компьютерная автоматизация эксперимента»  
по направлению подготовки 01.03.02 Прикладная математика и информатика, профиль «Математическое моделирование»  
ФГБОУ ВО «ЧелГУ»

Версия документа - 1

стр. 24 из 24

Первый экземпляр \_\_\_\_\_

КОПИЯ № \_\_\_\_\_

физических величин в цифровую форму;

- студент способен давать ответы на теоретические вопросы дисциплины, использовать базовые термины; представлять в контрольной общие характеристики объекта, предмета, цели, задач компьютерной автоматизации эксперимента; интерпретировать учебную литературу и справочные источники по компьютерной автоматизации эксперимента.

## 2. Базовый уровень:

- предполагает формирование компетенций на более высоком уровне: формируется знание методологии преобразования различных физических величин в цифровую форму, соответствующих терминов, основных научных трудов;
- студент способен давать развернутые ответы на теоретические вопросы дисциплины; представлять в докладе подробные отличительные характеристики современных отраслей, методов автоматизации эксперимента; интерпретировать и анализировать научные труды по автоматизации эксперимента; использовать современные информационные технологии в основе схемотехнике.

## 3. Продвинутый уровень:

- предполагает формирование компетенций на высоком уровне, готовность к самостоятельной профессиональной деятельности: формируется знание о специфике современных информационных технологий в автоматизации эксперимента, системы терминов; актуальных направлениях компьютерной автоматизации эксперимента;
- студент способен использовать систему научных понятий компьютерной автоматизации эксперимента; глубоко раскрывать в докладе специфику современных информационных технологий в автоматизации эксперимента; самостоятельно применять теоретические знания для планирования исследования с помощью компьютерных технологий.