

Deep Learning with MATLAB

Roy Fahn

Application Engineer

royf@systematics.co.il

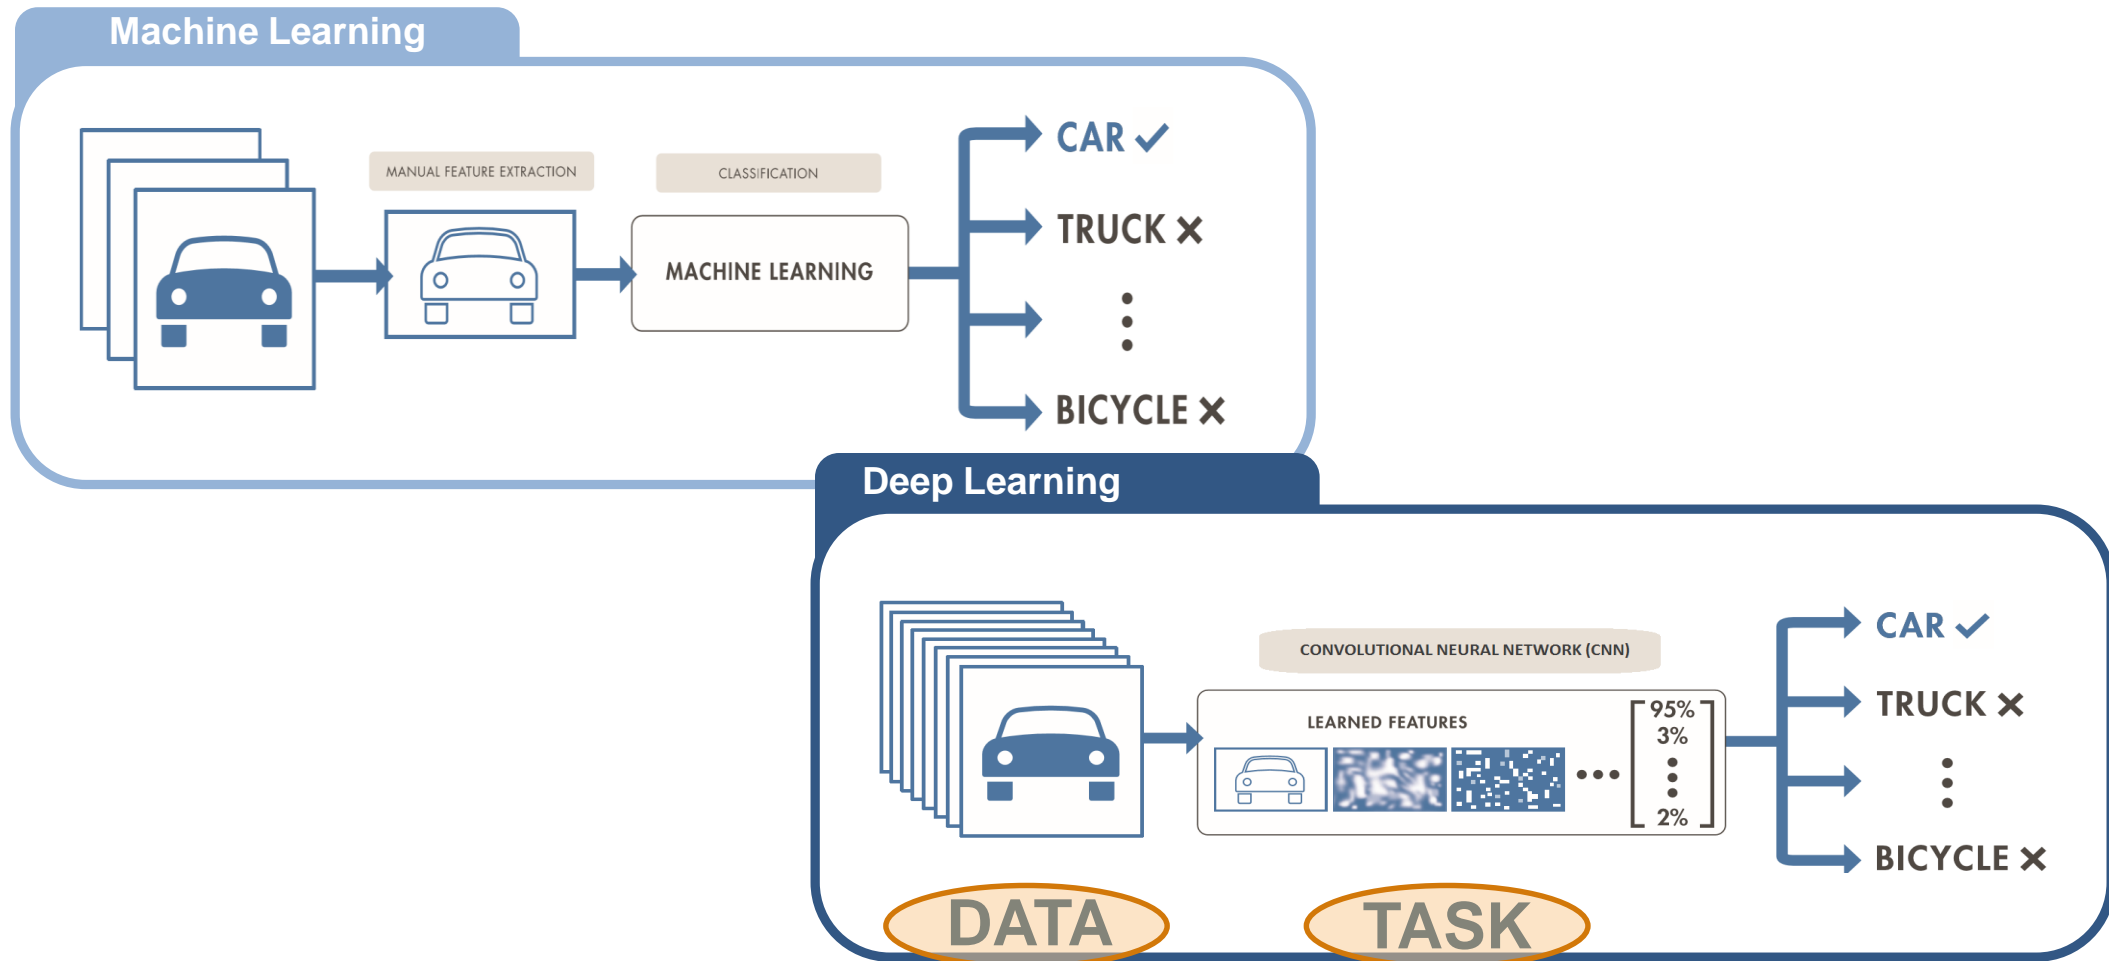
www.**Linked in**.com/in/royfahn

Blog: **MATLAB With Fun**

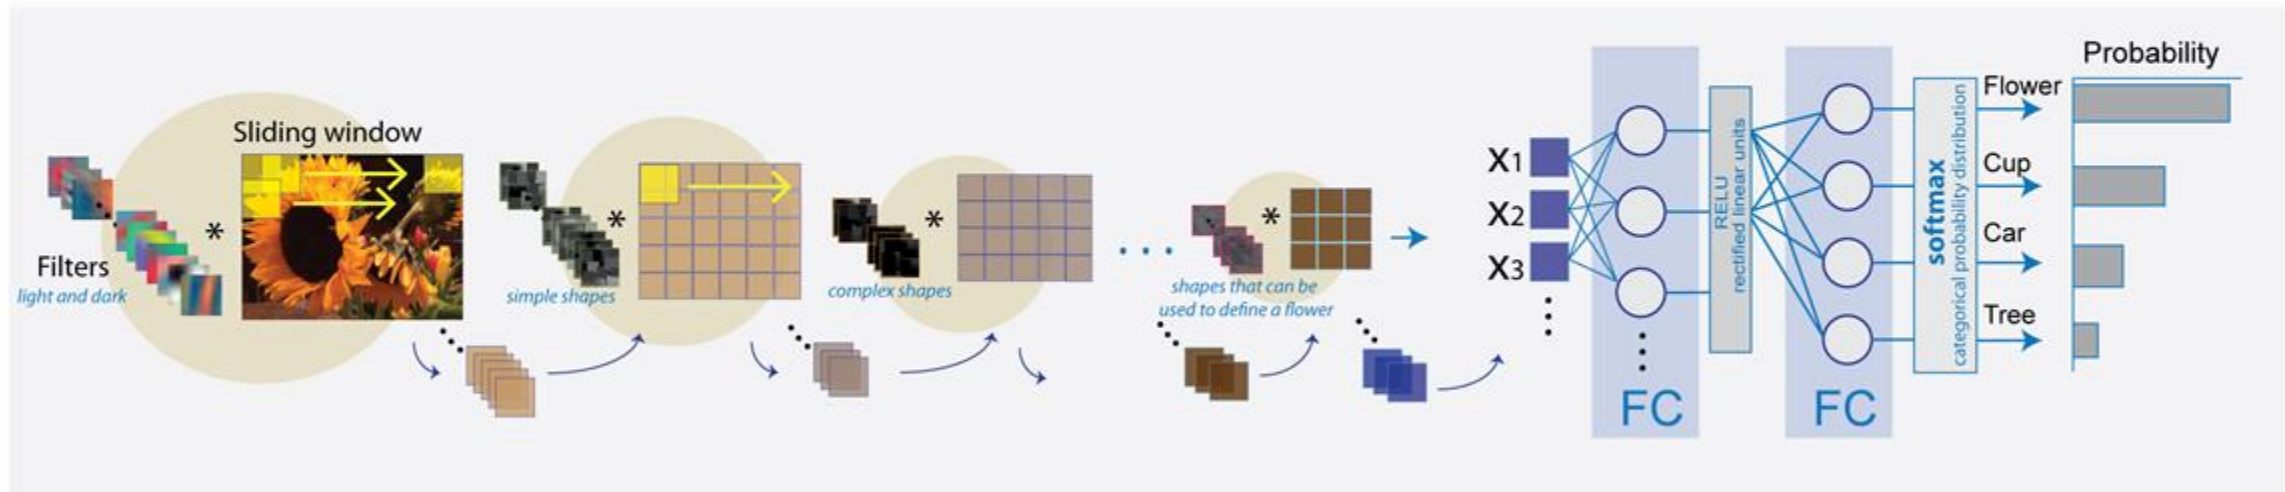

www.systematics.co.il/matlab-blog

What is Deep Learning ?


Deep learning is a **type of machine learning** that performs **end-to-end learning** by learning **tasks** directly from **images, text, and sound**.



Convolutional Neural Networks




Why is Deep Learning So Popular Now?





Deep Learning Enablers

Acceleration with GPUs



Massive sets of labeled data



Availability of state of the art models from experts

AlexNet
PRETRAINED
MODEL

VGG-16
PRETRAINED
MODEL

ResNet-50
PRETRAINED MODEL

ResNet-101
PRETRAINED MODEL

Caffe
IMPORTER


GoogLeNet
PRETRAINED
MODEL

**TensorFlow-
Keras**
IMPORTER

Inception-v3
MODELS

Challenges

- Handle and label large data sets
- Accelerate deep learning with GPUs
- Visualize and debug deep neural networks
- Access and use models from experts
- Deploy the trained model



AlexNet
PRETRAINED
MODEL

VGG-16
PRETRAINED
MODEL

Caffe
IMPORTER


GoogLeNet
PRETRAINED
MODEL

ResNet-50
PRETRAINED MODEL

ResNet-101
PRETRAINED MODEL

**TensorFlow-
Keras**
IMPORTER

Inception-v3
MODELS



MATLAB makes deep learning easy and accessible

MATLAB makes Deep Learning Easy and Accessible

New MATLAB capabilities to

- Handle and label large data sets
- Accelerate deep learning with GPUs
- Visualize and debug deep neural networks
- Access and use models from experts
- Deploy the trained model

```
imageDS = imageDatastore(dir)  
Easily manage large sets of images
```

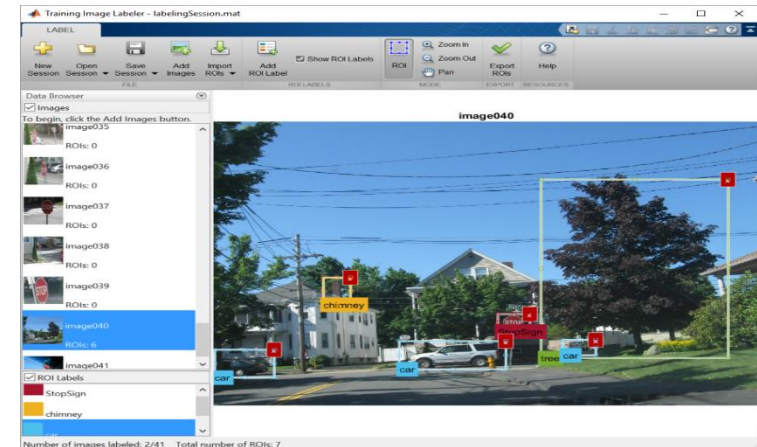

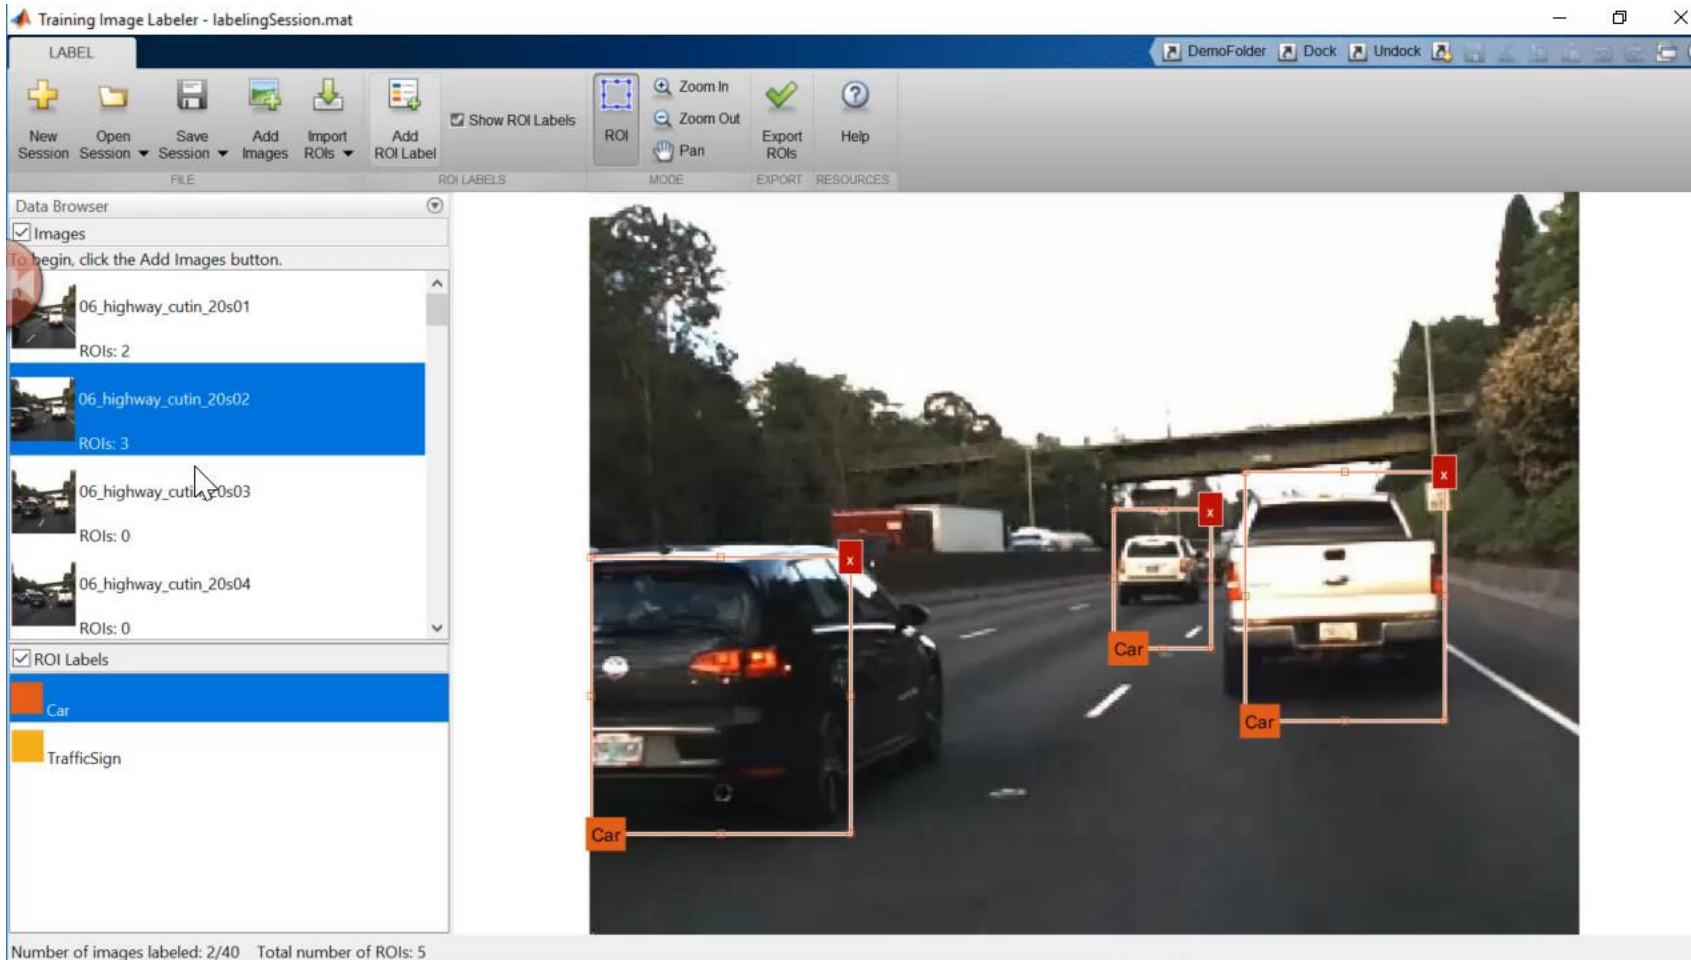


Image Labeler



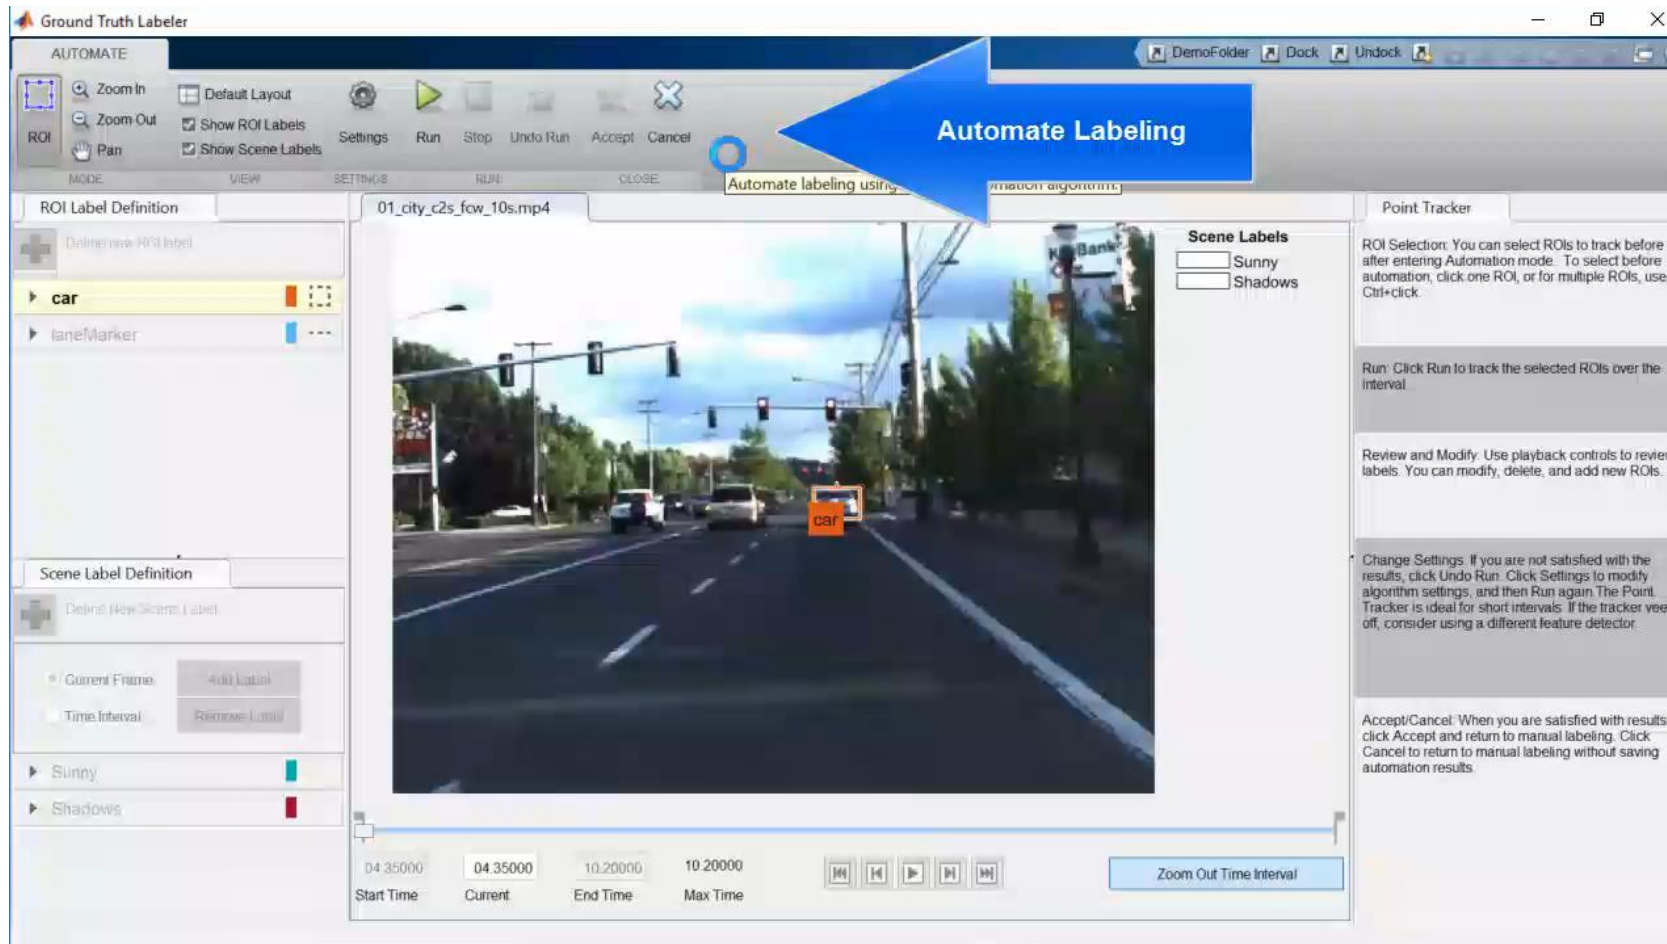
Video Labeler

Demo: Label Images with MATLAB




Easily label object(s) from the desired class(es)

Demo: Label Videos with MATLAB



Automate Ground Truth Labeling by running custom or pre-built trackers

R-CNN Vs. Semantic Segmentation

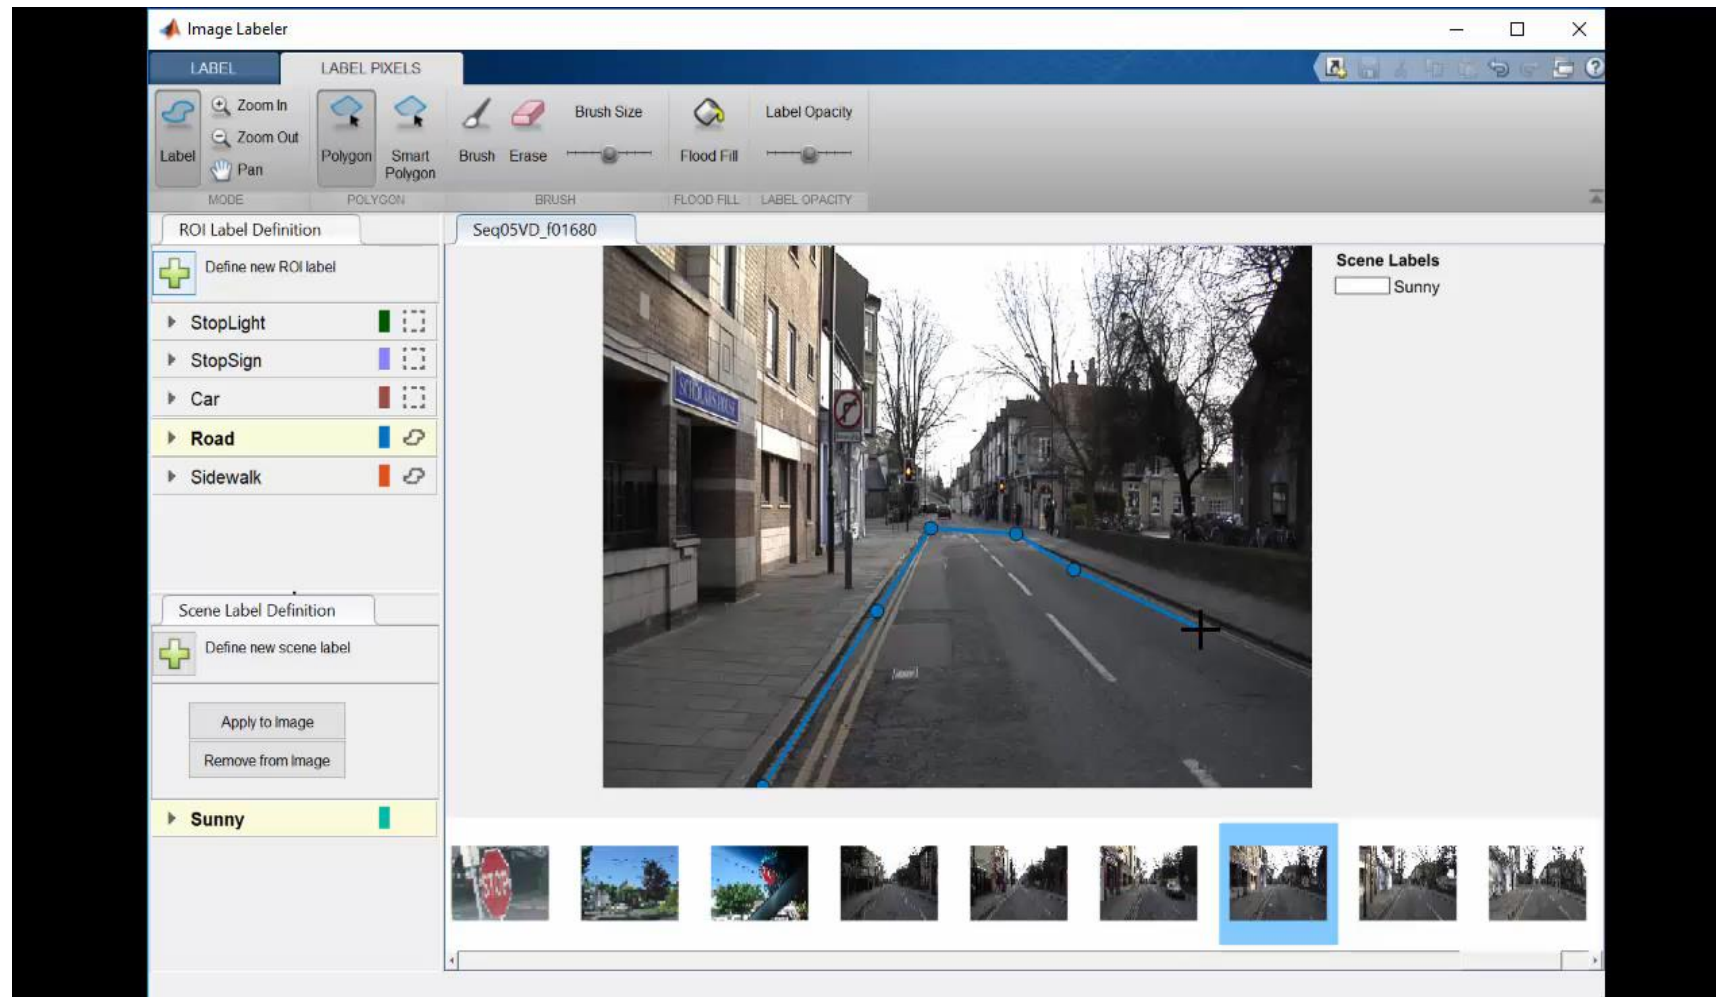


Regions with Convolutional Neural Network Features (R-CNN)



Semantic Segmentation using SegNet

Demo: Label Images and Videos at the Pixel Level



Essential for semantic segmentation

MATLAB makes Deep Learning Easy and Accessible

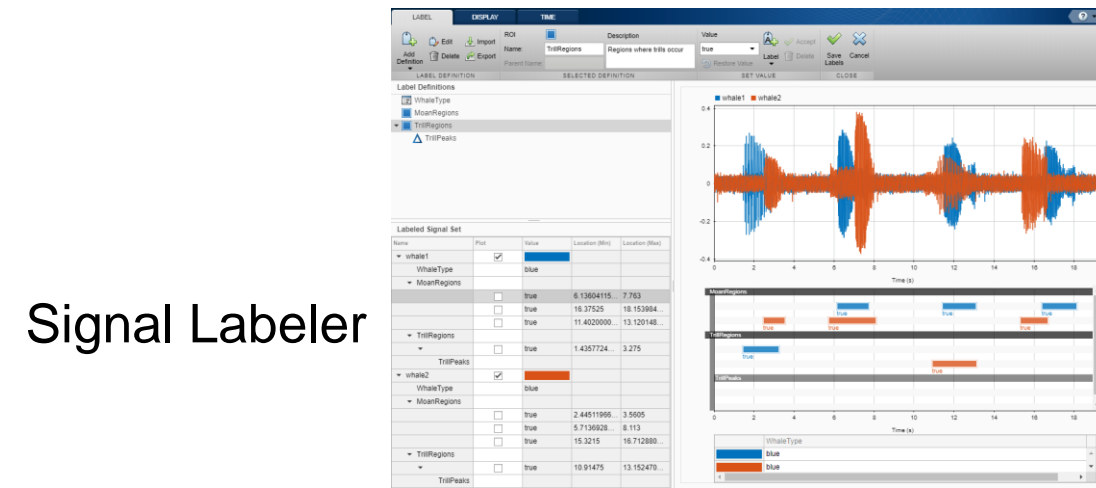
New MATLAB capabilities to

- Handle and label large data sets
- Accelerate deep learning with GPUs
- Visualize and debug deep neural networks
- Access and use models from experts
- Deploy the trained model

aDS = audioDatastore(dir)
Easily manage collection of audio files



Audio Labeler




Signal Labeler

MATLAB makes Deep Learning Easy and Accessible

New MATLAB capabilities to

- Handle and label large data sets
- Accelerate deep learning with GPUs
- Visualize and debug deep neural networks
- Access and use models from experts
- Deploy the trained model

Acceleration with Multiple GPUs




Deep learning on CPU, GPU, multi-GPU and clusters

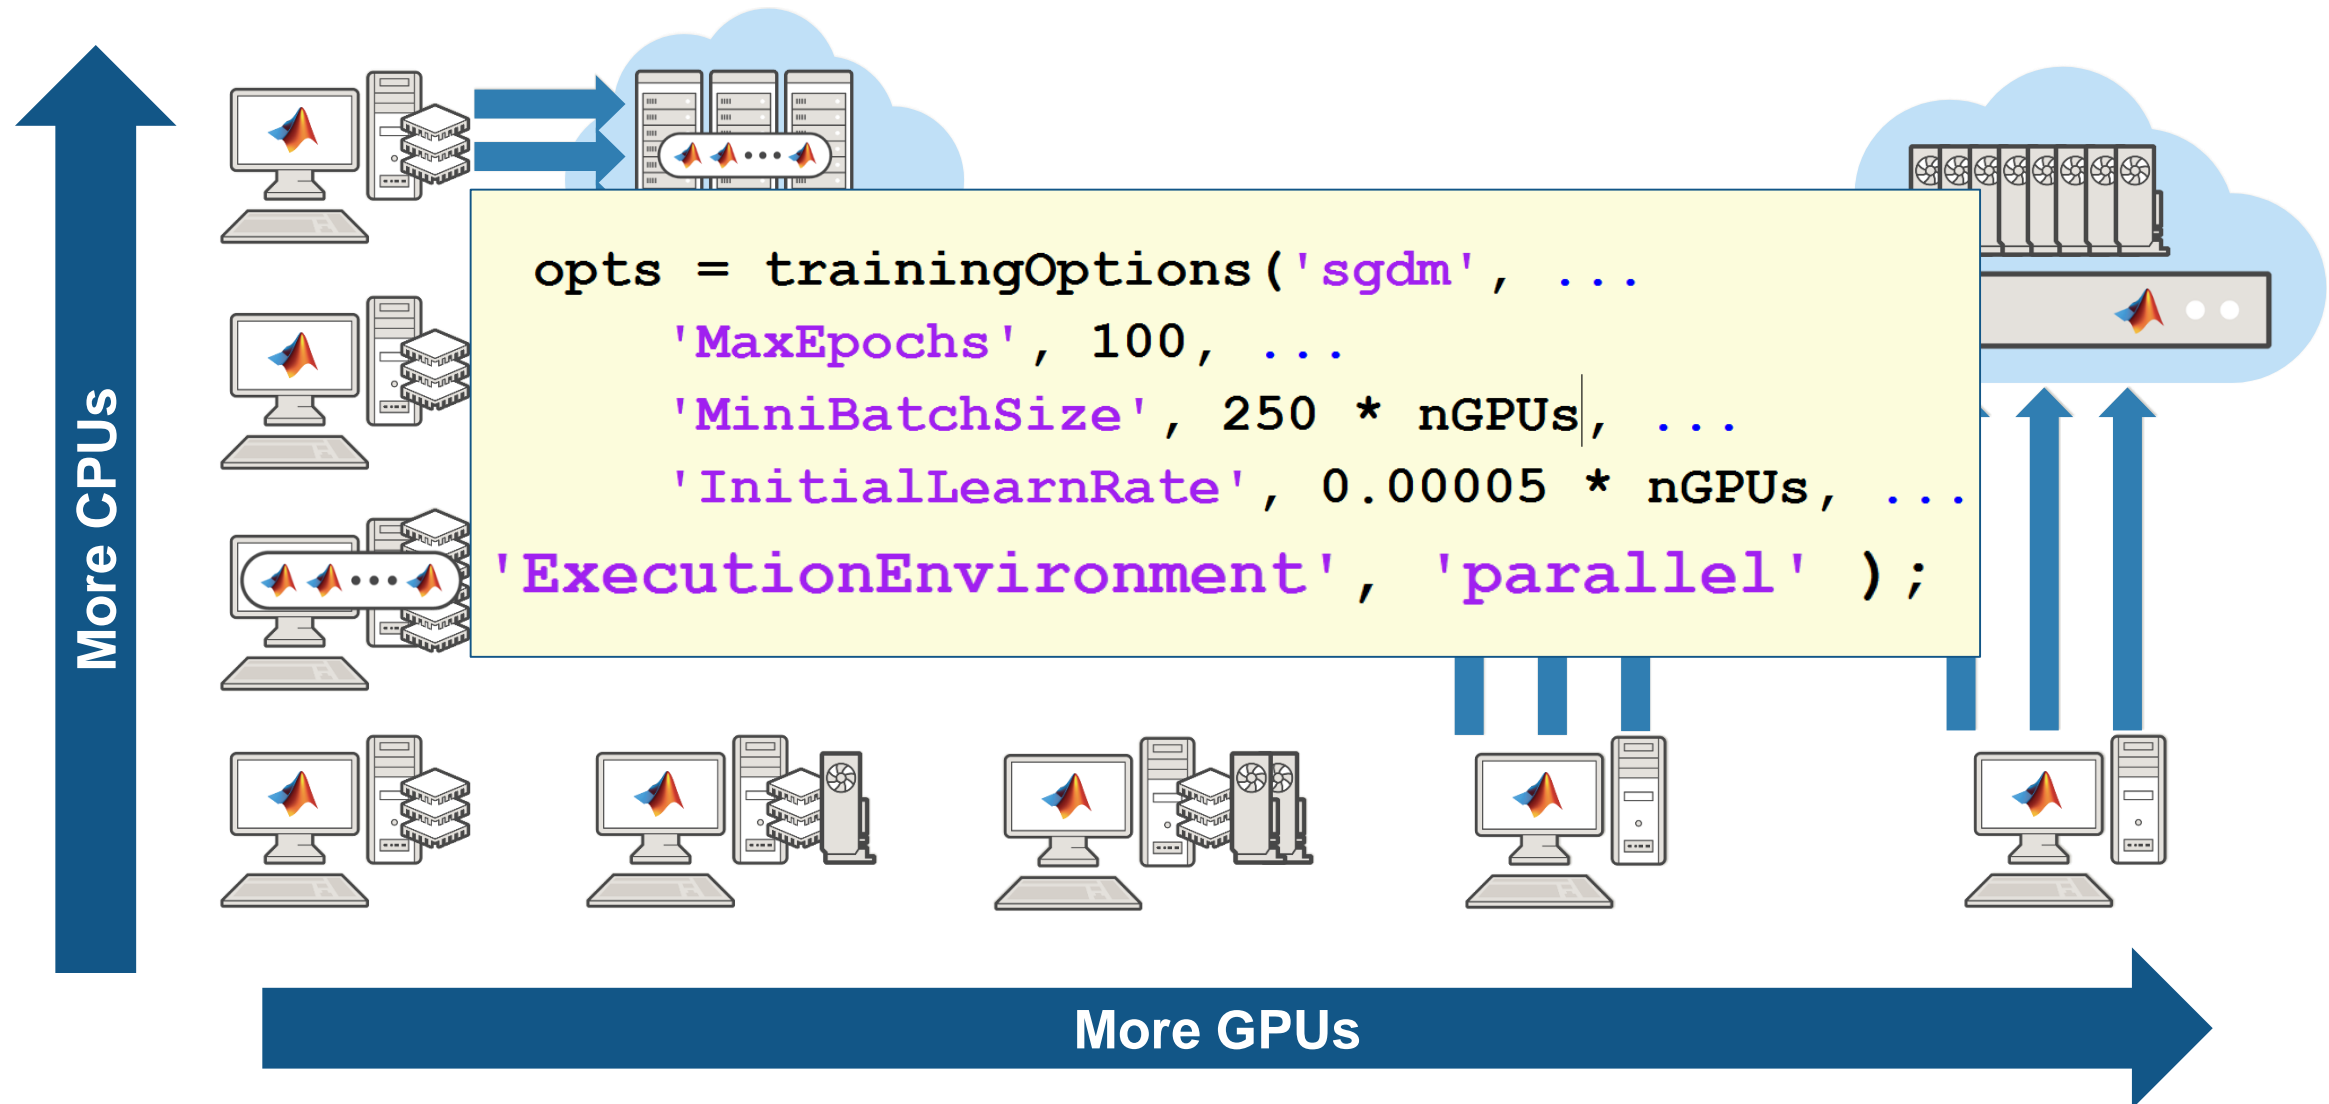


More GPUs


Deep learning on CPU, GPU, multi-GPU and clusters



Deep learning on CPU, GPU, multi-GPU and clusters



Training in MATLAB is fast




AlexNet CNN architecture trained on the ImageNet dataset, using batch size of 32, on a Windows 10 desktop with single NVIDIA GPU

MATLAB makes Deep Learning Easy and Accessible

New MATLAB capabilities to


- Handle and label large data sets
- Accelerate deep learning with GPUs
- Visualize and debug deep neural networks
- Access and use models from experts
- Deploy the trained model



Training Accuracy Plot




Deep Dream

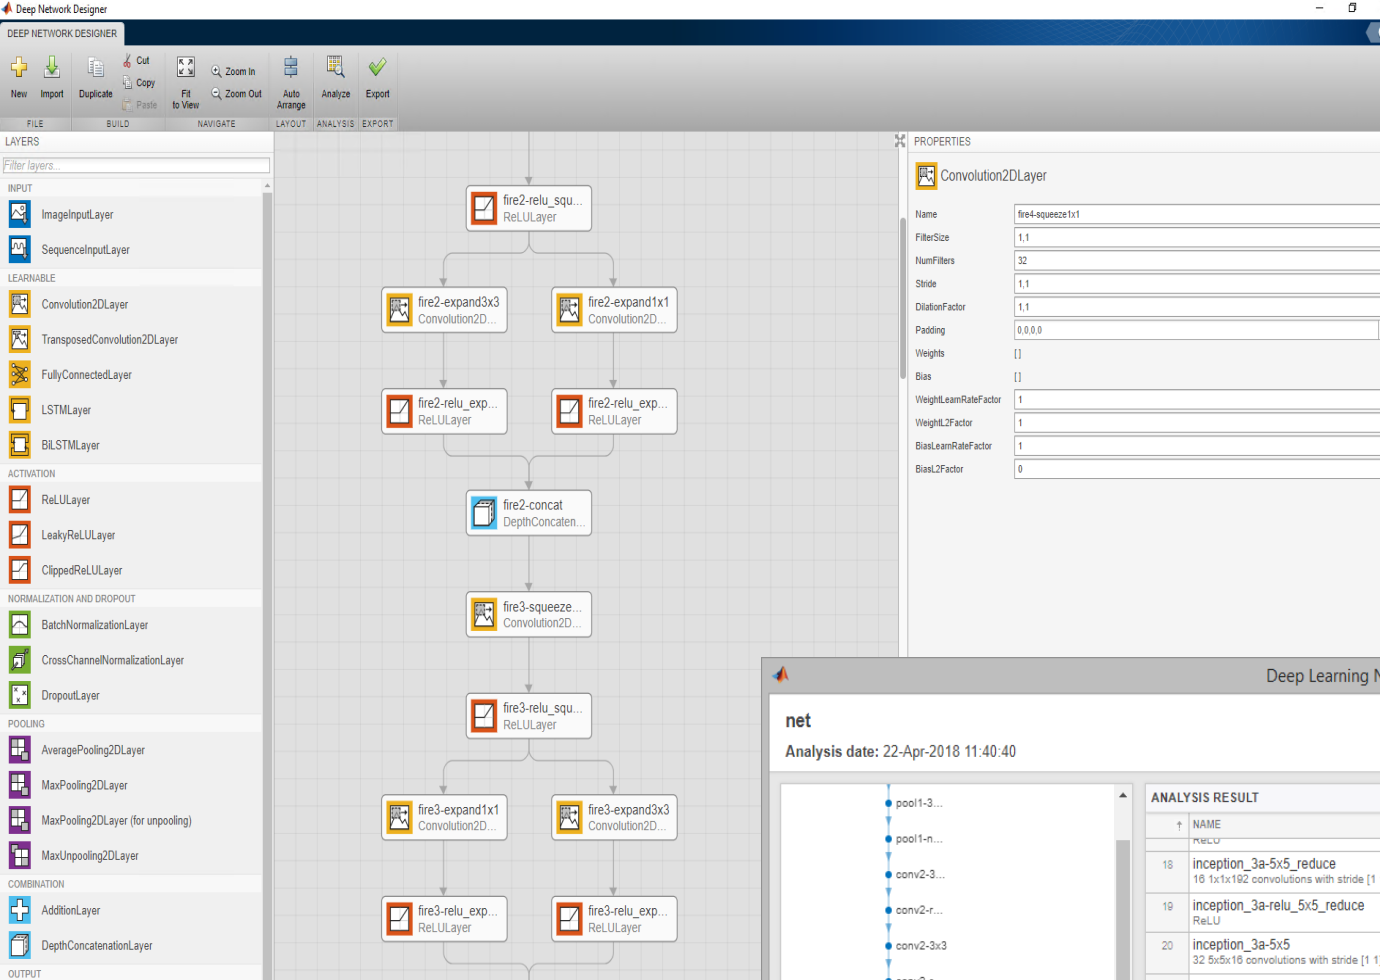


Network Activations

Layer conv3 Features

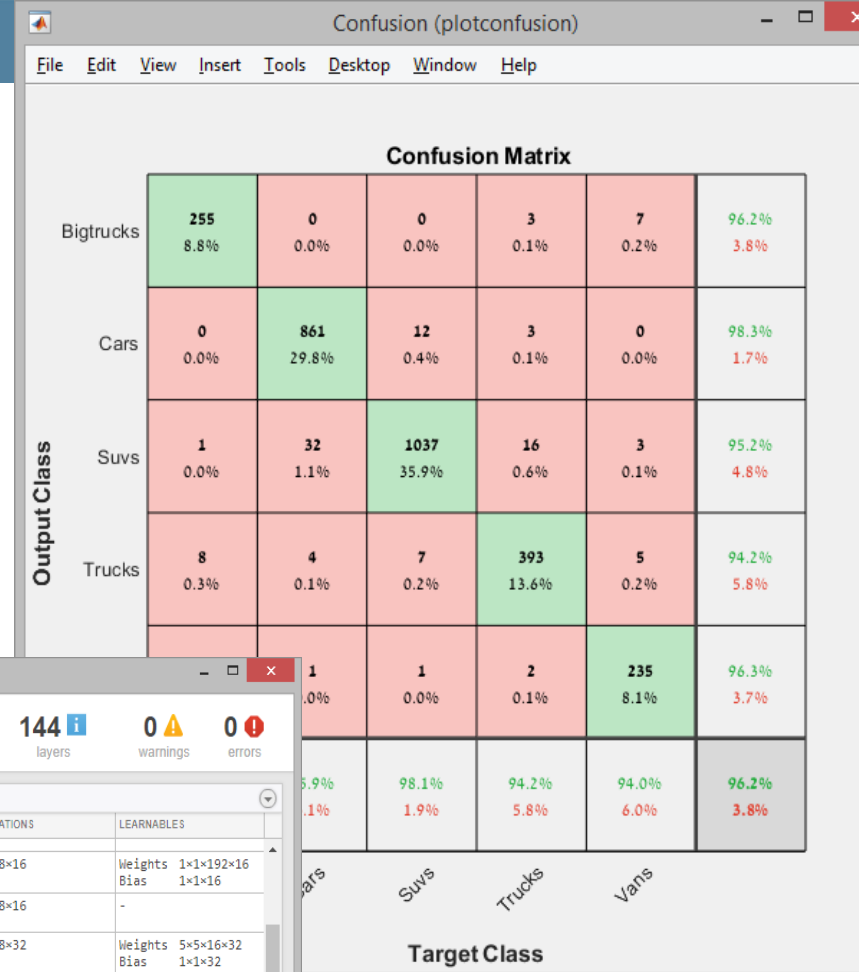
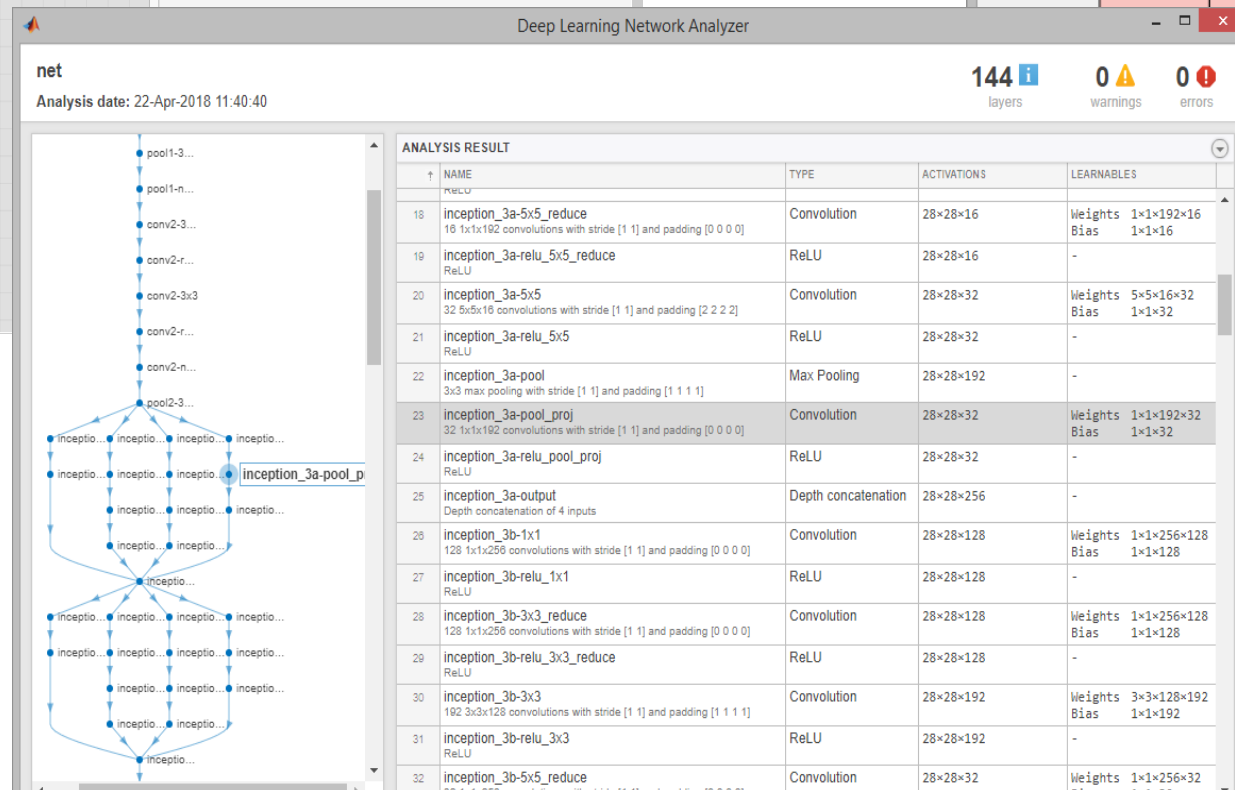


Feature Visualization



Deep Network Designer

Network Analyzer



Confusion Matrix

MATLAB makes Deep Learning Easy and Accessible

New MATLAB capabilities to

- Handle and label large data sets
- Accelerate deep learning with GPUs
- Visualize and debug deep neural networks
- Access and use models from experts
- Deploy the trained model

Curated Set of Pretrained Models

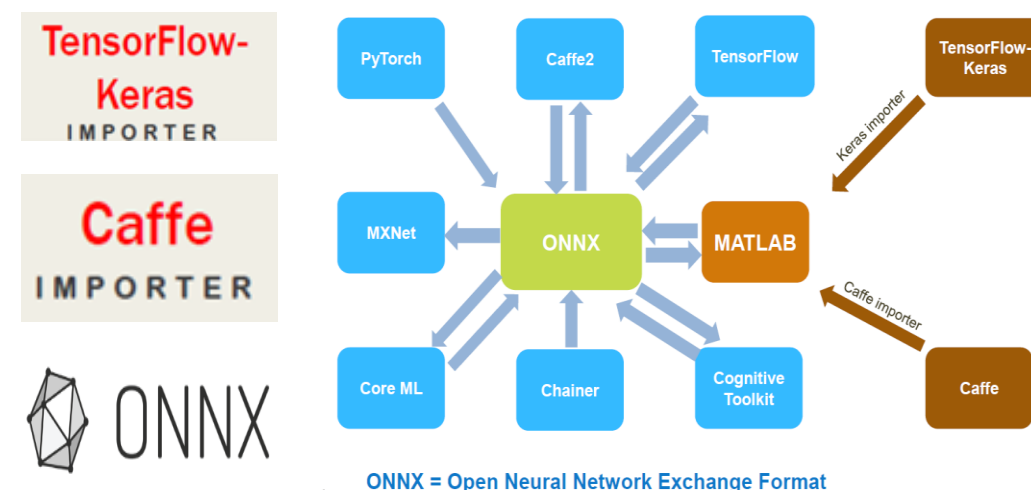
Complete list:

www.mathworks.com/solutions/deep-learning/models.html

Access Models with 1-line of MATLAB Code

```
Net1 = alexnet  
Net2 = vgg16  
Net3 = vgg19  
Net4 = resnet50  
Net5 = googlenet
```

Interface with Other Frameworks



MATLAB makes Deep Learning Easy and Accessible

New MATLAB capabilities to

- Handle and label large data sets
- Accelerate deep learning with GPUs
- Visualize and debug deep neural networks
- Access and use models from experts
- Deploy the trained model


**MATLAB
Compiler**

**MATLAB
Production
Server**

**MATLAB
Coder**

GPU Coder

Desktop Apps




Enterprise Scale Systems

Java
MATLAB
C/C++
Python

Embedded Devices and Hardware




With GPU Coder, MATLAB is fast




GPU Coder
is faster than
TensorFlow,
MXNet, and
PyTorch

Benchmarking Resnet-50 on GPUs

Platform	Back-end	Latency (ms)		Speedup over TensorFlow
		MATLAB GPU Coder	TensorFlow v1.7	
(desktop) Titan XP	cuDNN v7	4.6	12.8	 2.8x
	TensorRT v3.0.4	2.3	3.0	1.3x
	TensorRT v3.0.4 (int8)	1.0	1.5	1.5x
(embedded) Jetson TX2	cuDNN v7	45.4		
	TensorRT v3.0.4	19.6		

Create CNNs with MATLAB, Deploy with GPU Coder

Alexnet



Vehicle
Detection




People detection





Lane detection



Alexnet Inference on Jetson TX2: Memory Performance



Benchmarking Resnet-50 on CPUs

Platform	Back-end	Latency (ms)			MATLAB Coder Speedup over	
		MATLAB Coder	TensorFlow v1.6	Caffe	Tensor Flow	Caffe
(desktop) 12-core Intel Xeon E5-1650	MKL-DNN v13	71	232	91	3.3x 	1.2x
(embedded) Raspberry Pi3	ARM Compute Library	2000		50000		25.0x 

Deep learning features summary

- Classification
- Regression
- Semantic segmentation
- Object detection
- Scalability
 - Multiple GPUs
 - Cluster or cloud
- Custom network layers
- ONNX Import/Export
- Import models
 - Caffe
 - Keras/TensorFlow
- Data augmentation
- Hyperparameter tuning
 - Bayesian optimization
- Python ↔ MATLAB interface
- LSTM networks
 - Time series, signals, audio
- Custom labeling
 - API for ground-truth labeling automation
 - Superpixels
- Data validation
 - Training and testing

Demos




Image classification using pre-trained network

Train a network to classify new objects

Locate & classify objects in images and video

Speech command recognition

Music genre recognition with wavelet Scattering

Demos




Image classification using pre-trained network

Train a network to classify new objects

Locate & classify objects in images and video

Speech command recognition

Music genre recognition with wavelet Scattering

Demo: Image Classification Using Pre-trained Network

```
ClassificationWithPreTrained.m x +
1  %% Load Pre-trained CNN
2  % This network is available from our add-ons location in the home tab.
3  % You can use a variety of pretrained networks available for download
4  net = alexnet;
5  % net = vgg16;
6  % net = vgg19;
7
8  %% Classify 'peppers' in 4 lines of code
9  % This is a great opportunity to inspect the network and look at the input
10 % layer. There is a size requirement of 227 x 227 for AlexNet.
11 % If you try to classify without resizing, you will get an error
12 im = imread('peppers.png');
13 imshow(im);
14 im = imresize(im,[227 227]);
15 classify(net,im)
16
17
```



Demos




Image classification using pre-trained network

Train a network to classify new objects

Locate & classify objects in images and video

Speech command recognition

Music genre recognition with wavelet Scattering


Why Train a New Model ?

- Models from research do not work on your data
- Pre-trained model not available for your data type
- Improve results by creating a model specific to your problem

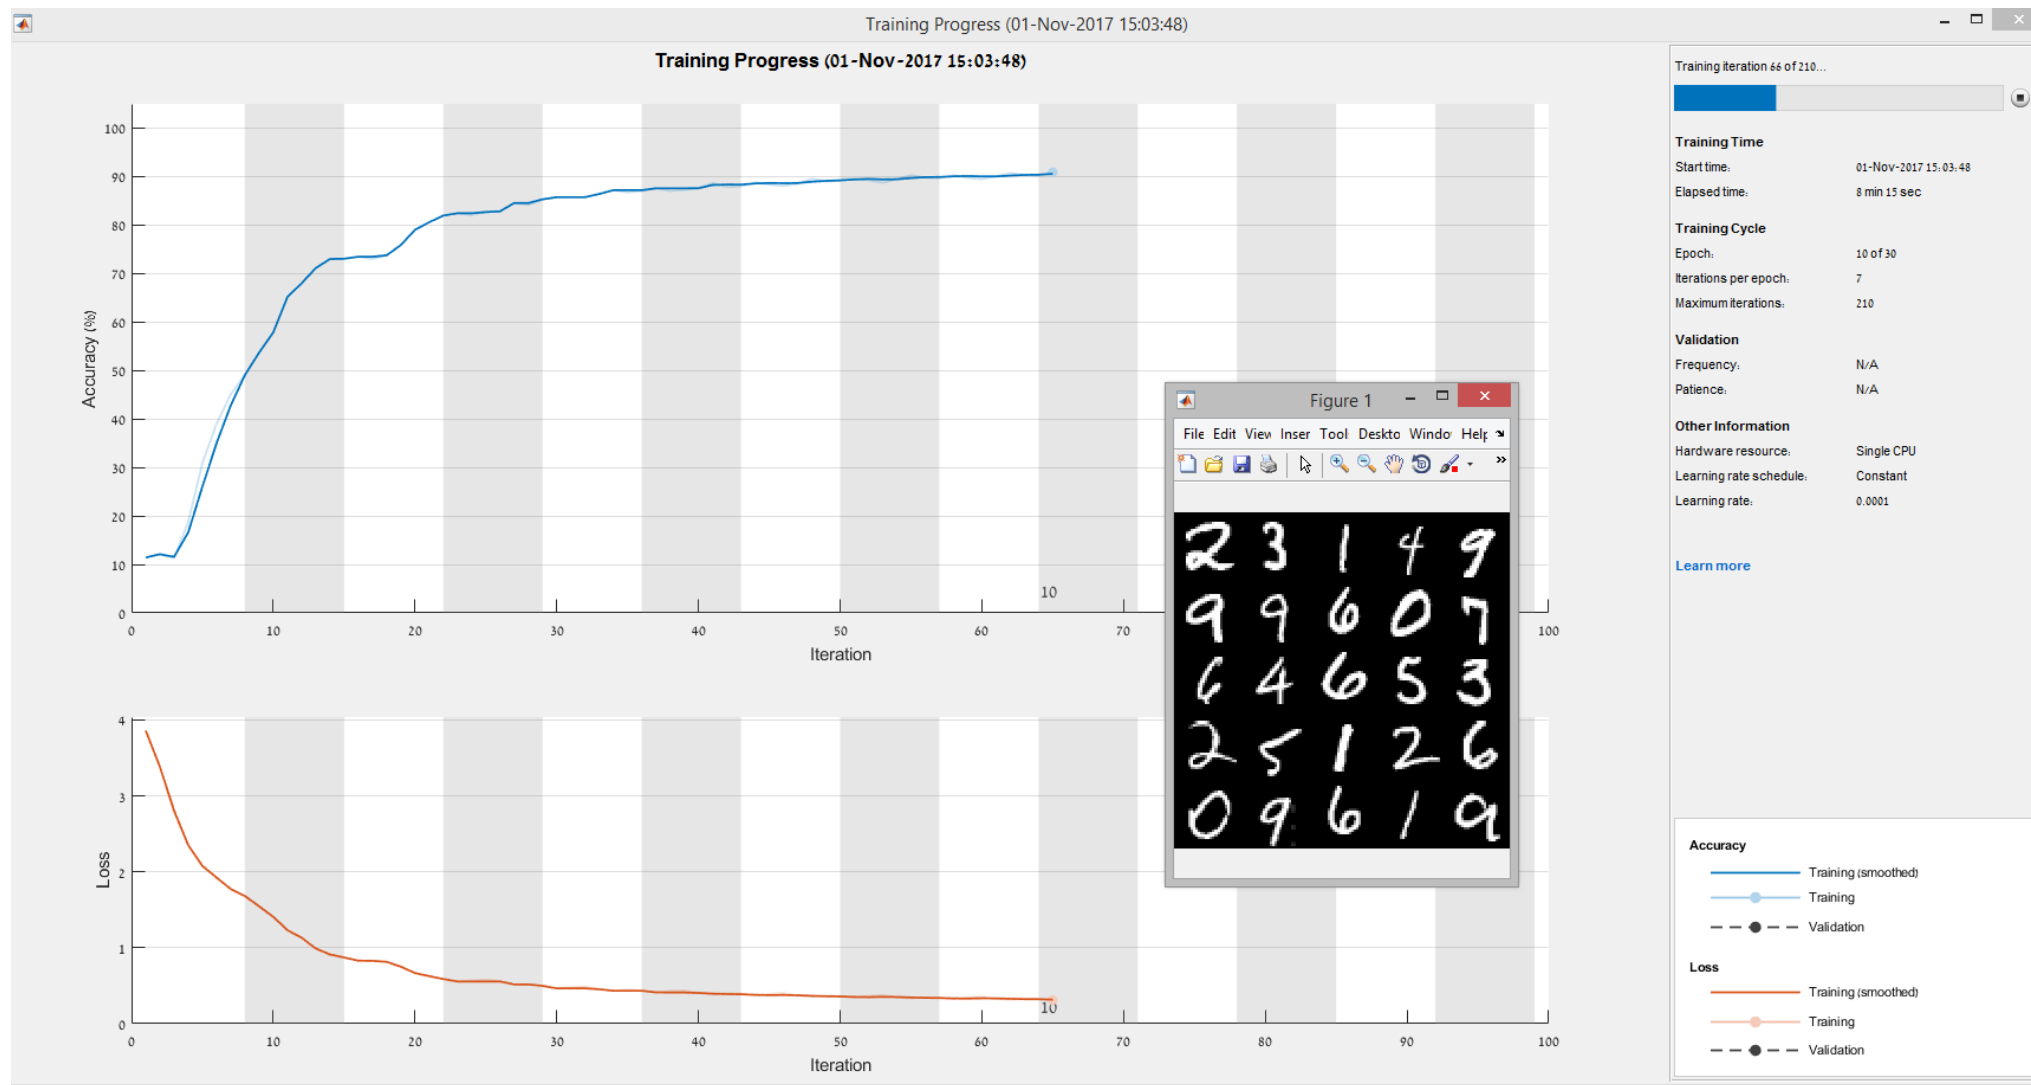


Two Approaches for Deep Learning

1. Train a Deep Neural Network from Scratch




Demo: Train from Scratch to Classify New Objects

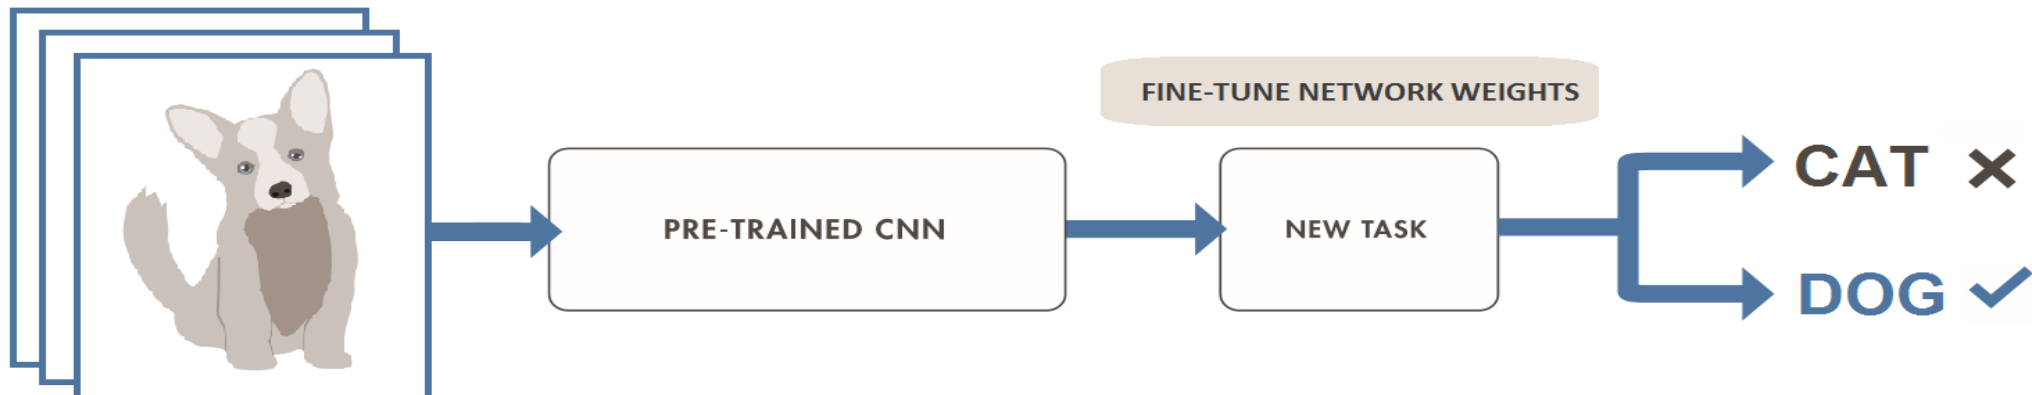


Two Approaches for Deep Learning

1. Train a Deep Neural Network from Scratch




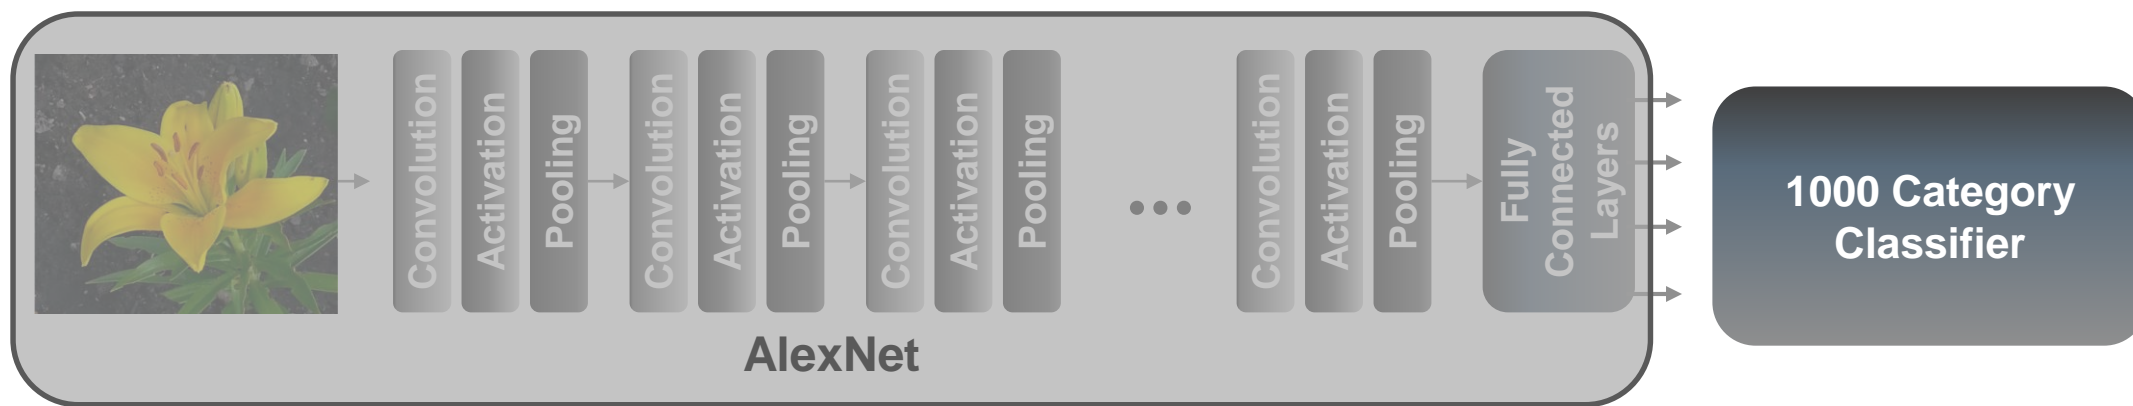
2. Fine-tune a pre-trained model (transfer learning)




Why Perform Transfer Learning

- Requires less data and training time
- Reference models (like AlexNet, VGG-16, VGG-19) are great feature extractors
- Leverage best network types from top researchers

Example: Classify Vehicles With Transfer Learning



New Data



car →

suv →

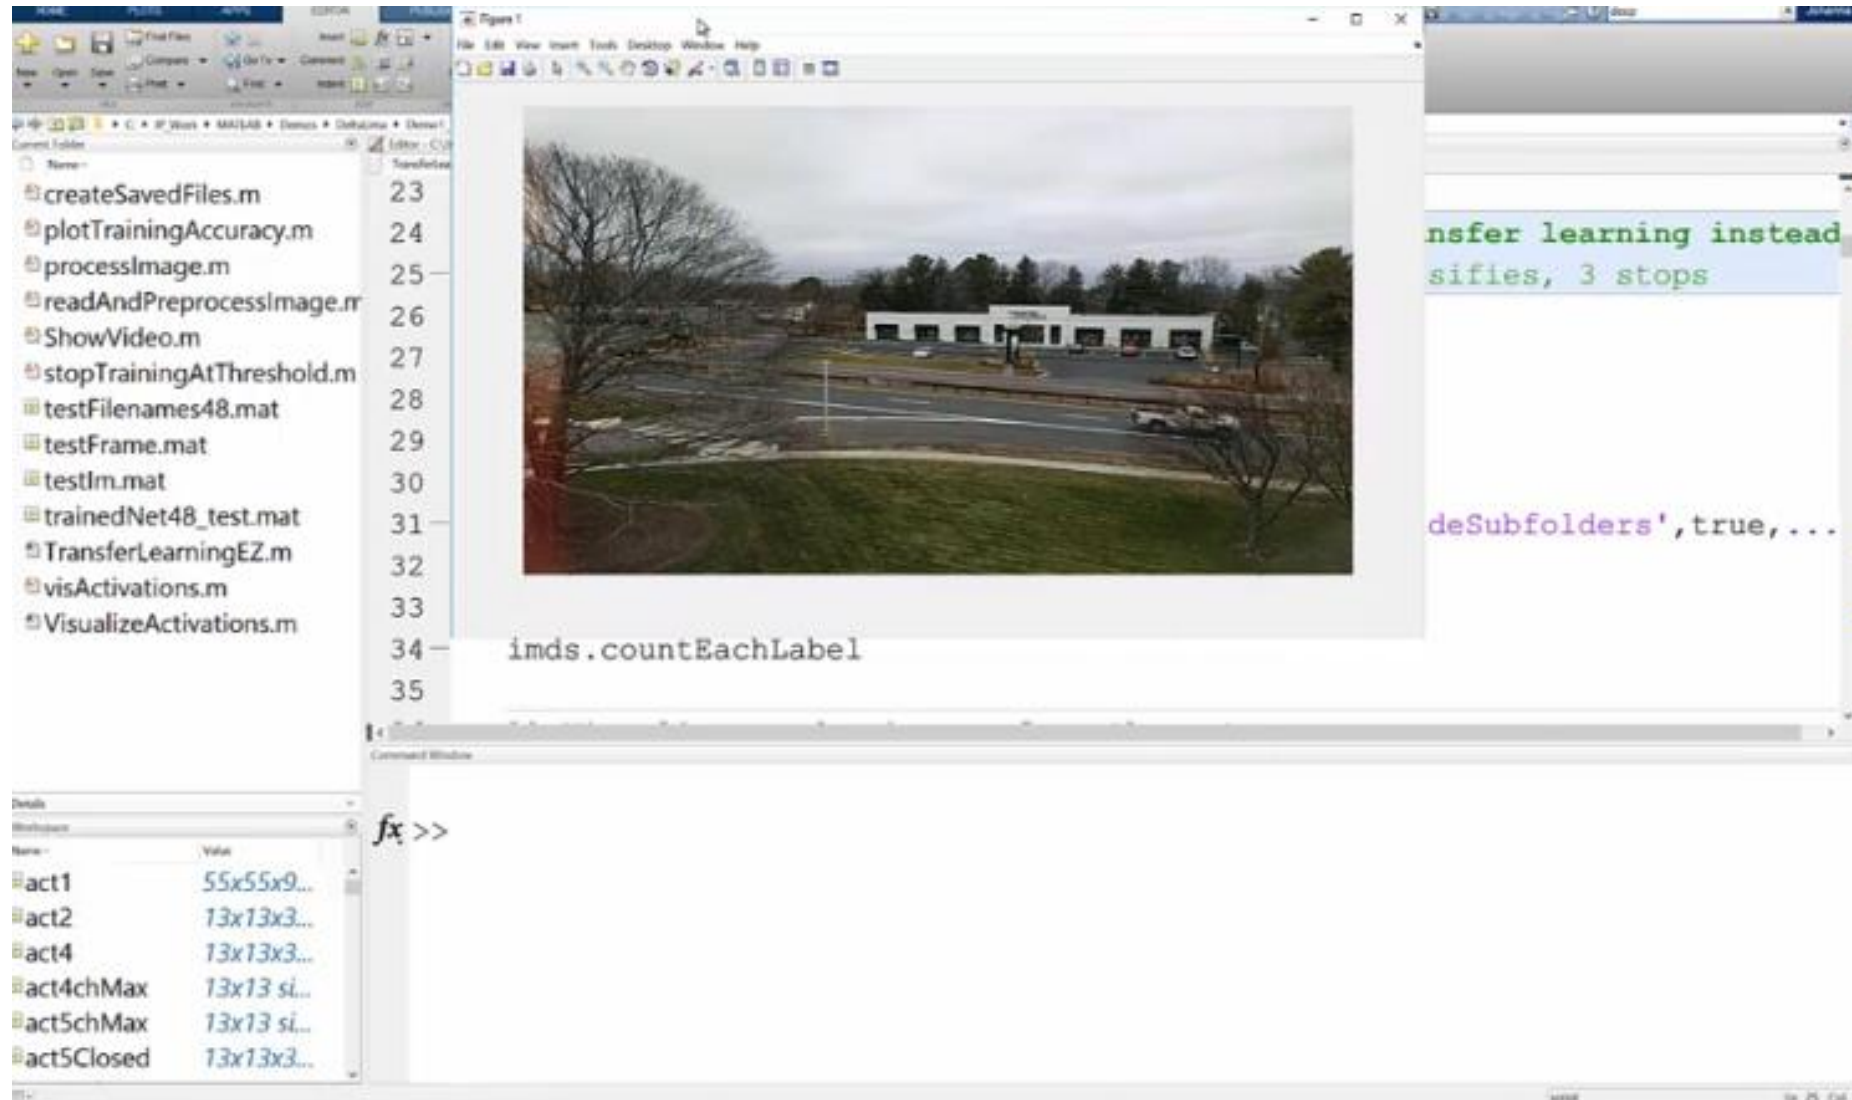
pickup →

van →

truck →

5 Category
Classifier

Demo: Transfer Learning to Classify New Objects



The image displays the MATLAB environment during a transfer learning demonstration. The main workspace shows a video frame of a parking lot with a building in the background. The Command Window displays the following code:

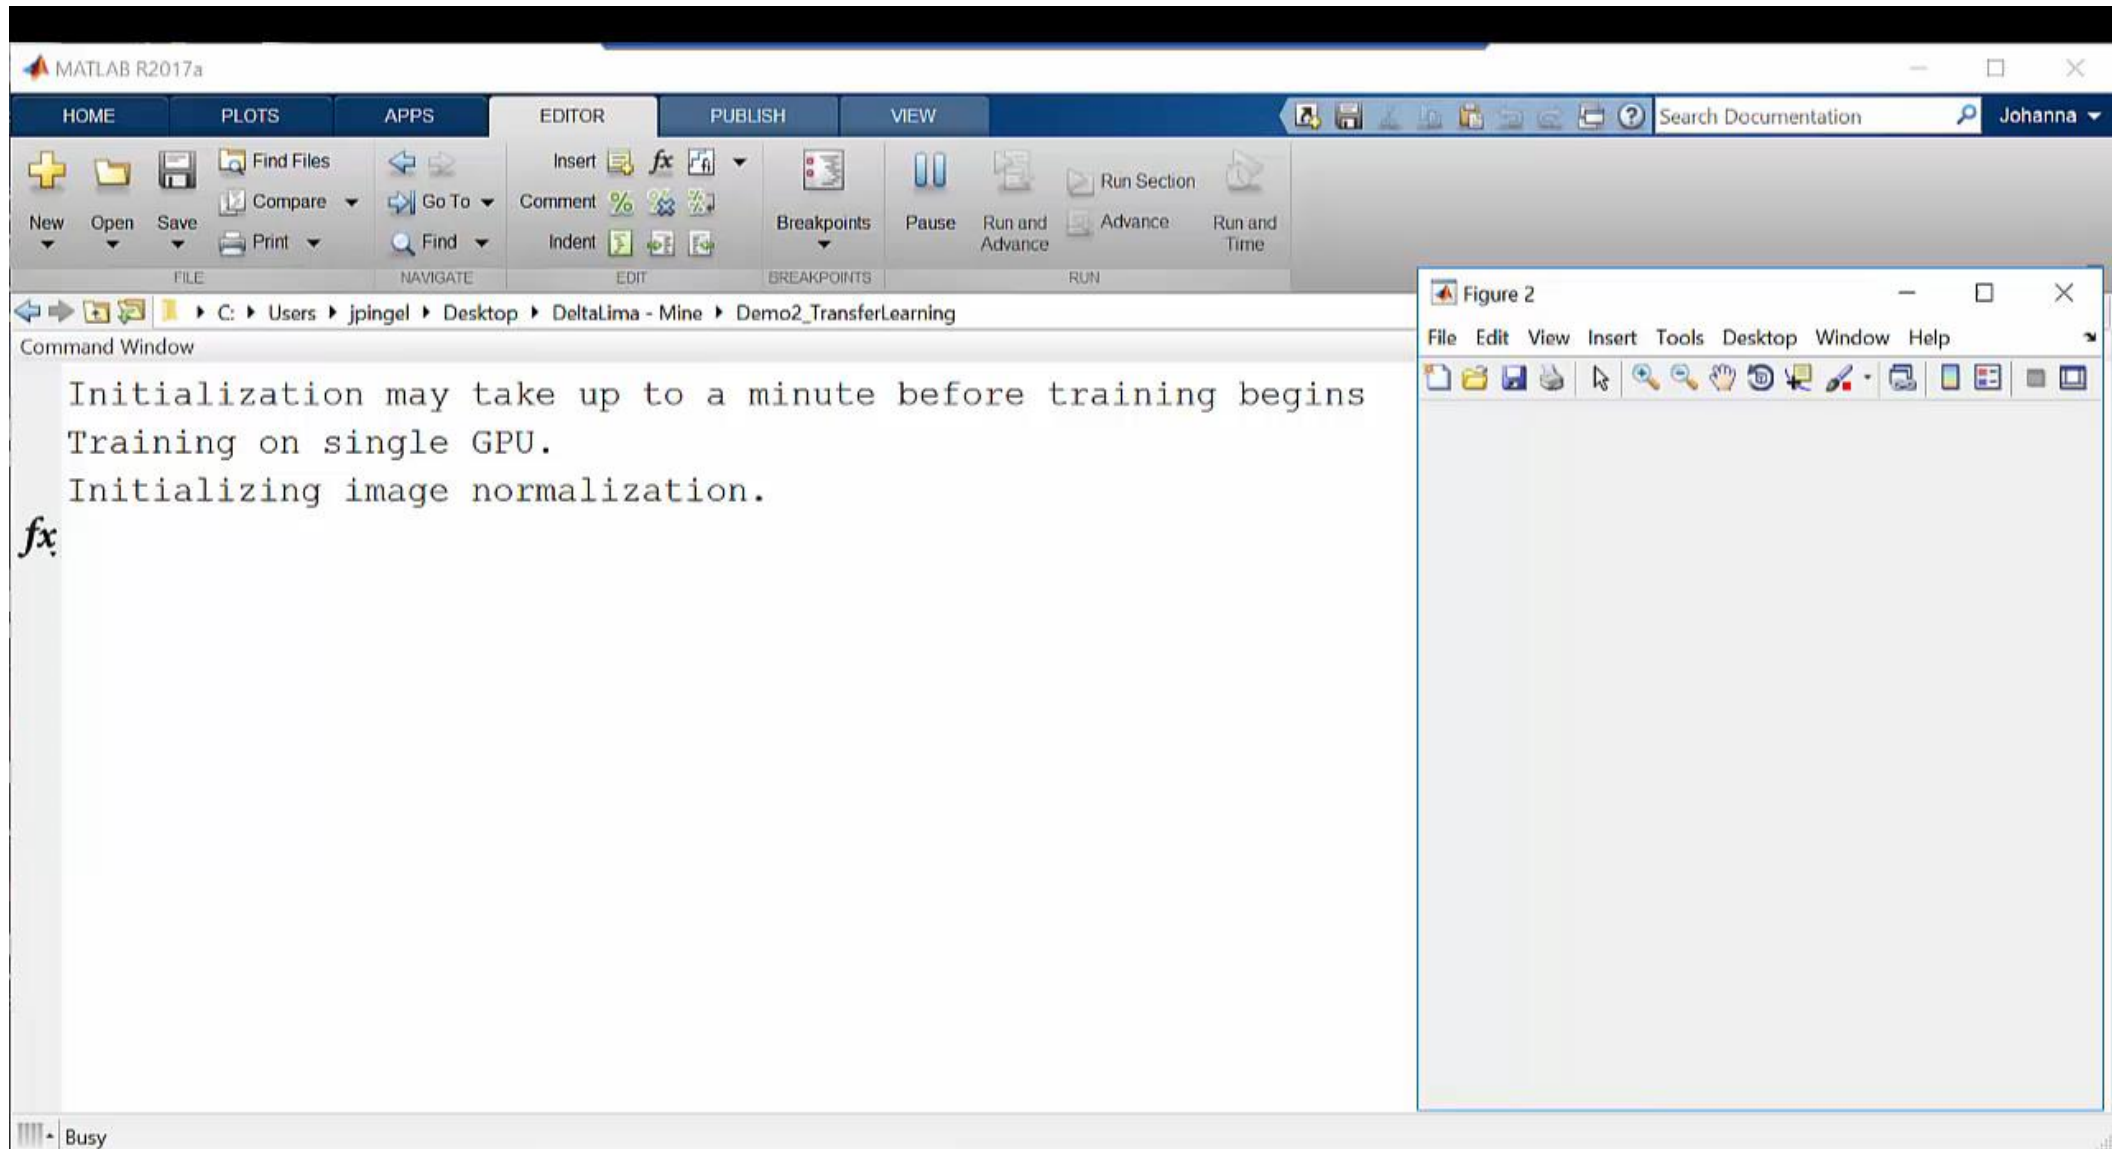
```
transfer learning instead  
sifies, 3 stops  
  
deSubfolders',true,...  
  
imds.countEachLabel
```

The Command Window also shows the prompt `fx >>`. The Variable Editor shows the following variables:

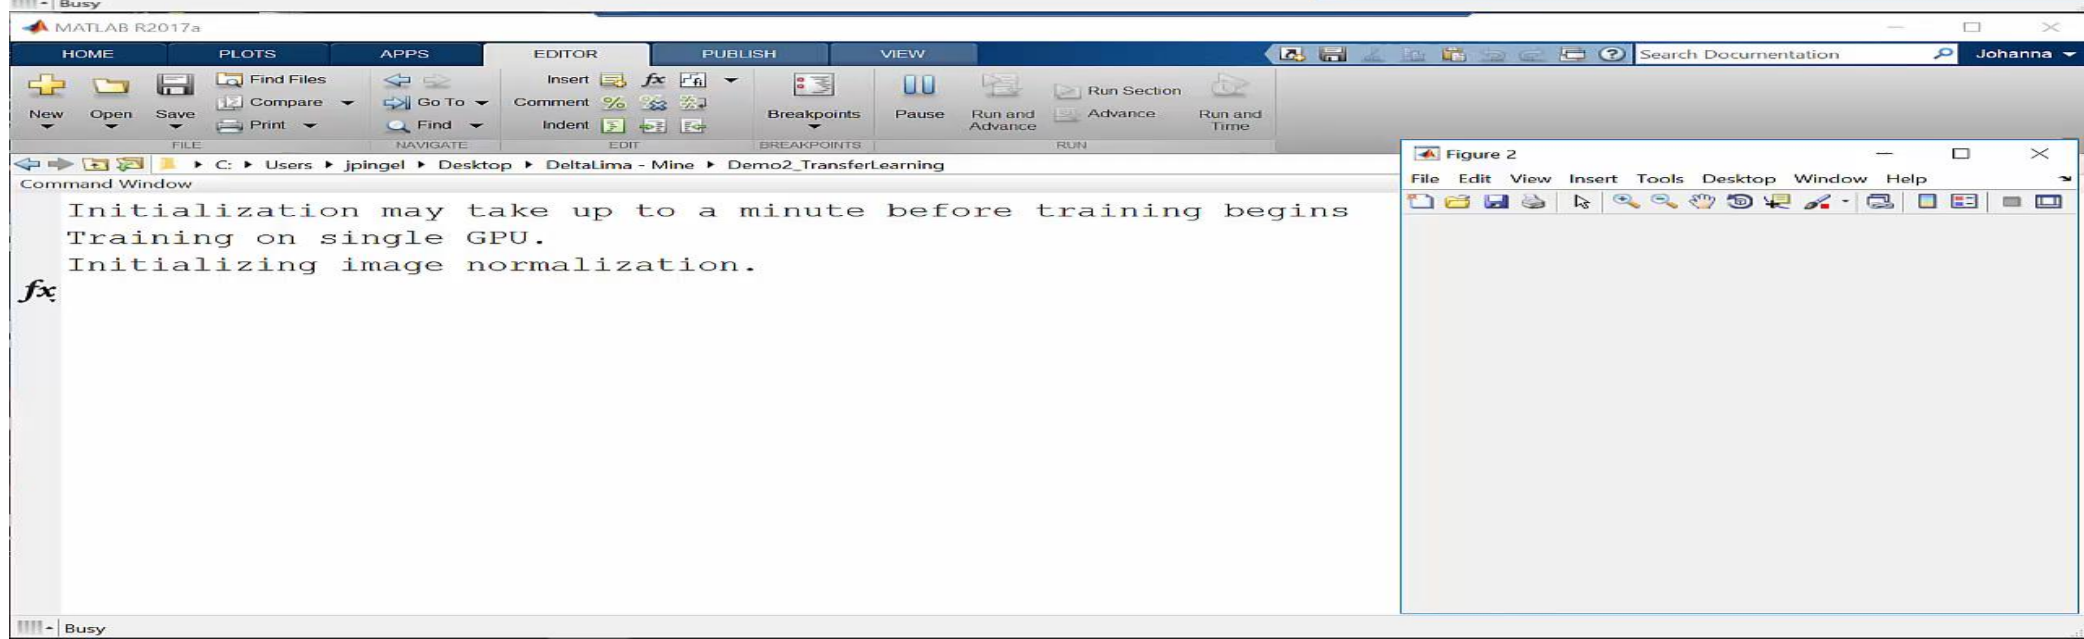
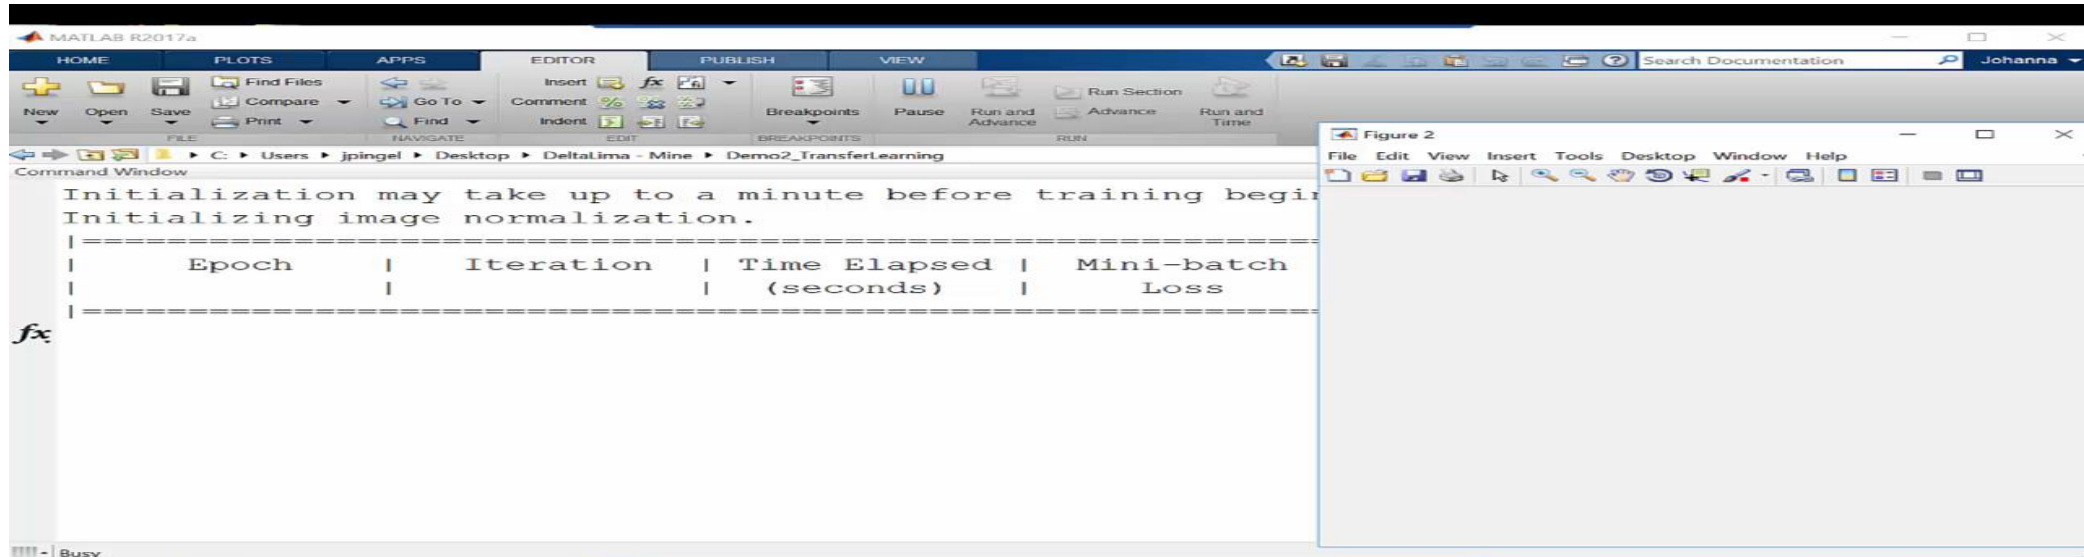
Name	Value
act1	55x55x9...
act2	13x13x3...
act4	13x13x3...
act4chMax	13x13 si...
act5chMax	13x13 si...
act5Closed	13x13x3...



Training Accuracy Vs. Iteration



GPU Vs. CPU



Regression Support for Deep Learning

Classification vs. Regression

- Classification – outputs categories/labels
- Regression – outputs numbers

Supported by new regression layer:

```
rouputlayer = regressionLayer('Name', 'rouput')
```

Example: Predict facial key-points:



Demos




Image classification using pre-trained network

Train a network to classify new objects

Locate & classify objects in images and video

Speech command recognition

Music genre recognition with wavelet Scattering

Is Object Recognition/Classification Enough ?

Car




Label for entire image



Car ? SUV? Truck?

Object Detection – Locate and Classify Object



Demo: Create Object Detector to Locate Vehicles



Step 1: Label / Crop data

Step 2: Train detector

Step 3: Use detector



Object Detection Frameworks in MATLAB

Machine Learning

1. Cascade Object Detector
2. Aggregate Channel Features (ACF)

Deep Learning

1. R-CNN
2. Fast R-CNN
3. Faster R-CNN



Same labels , train any detector.

Demos




Image classification using pre-trained network

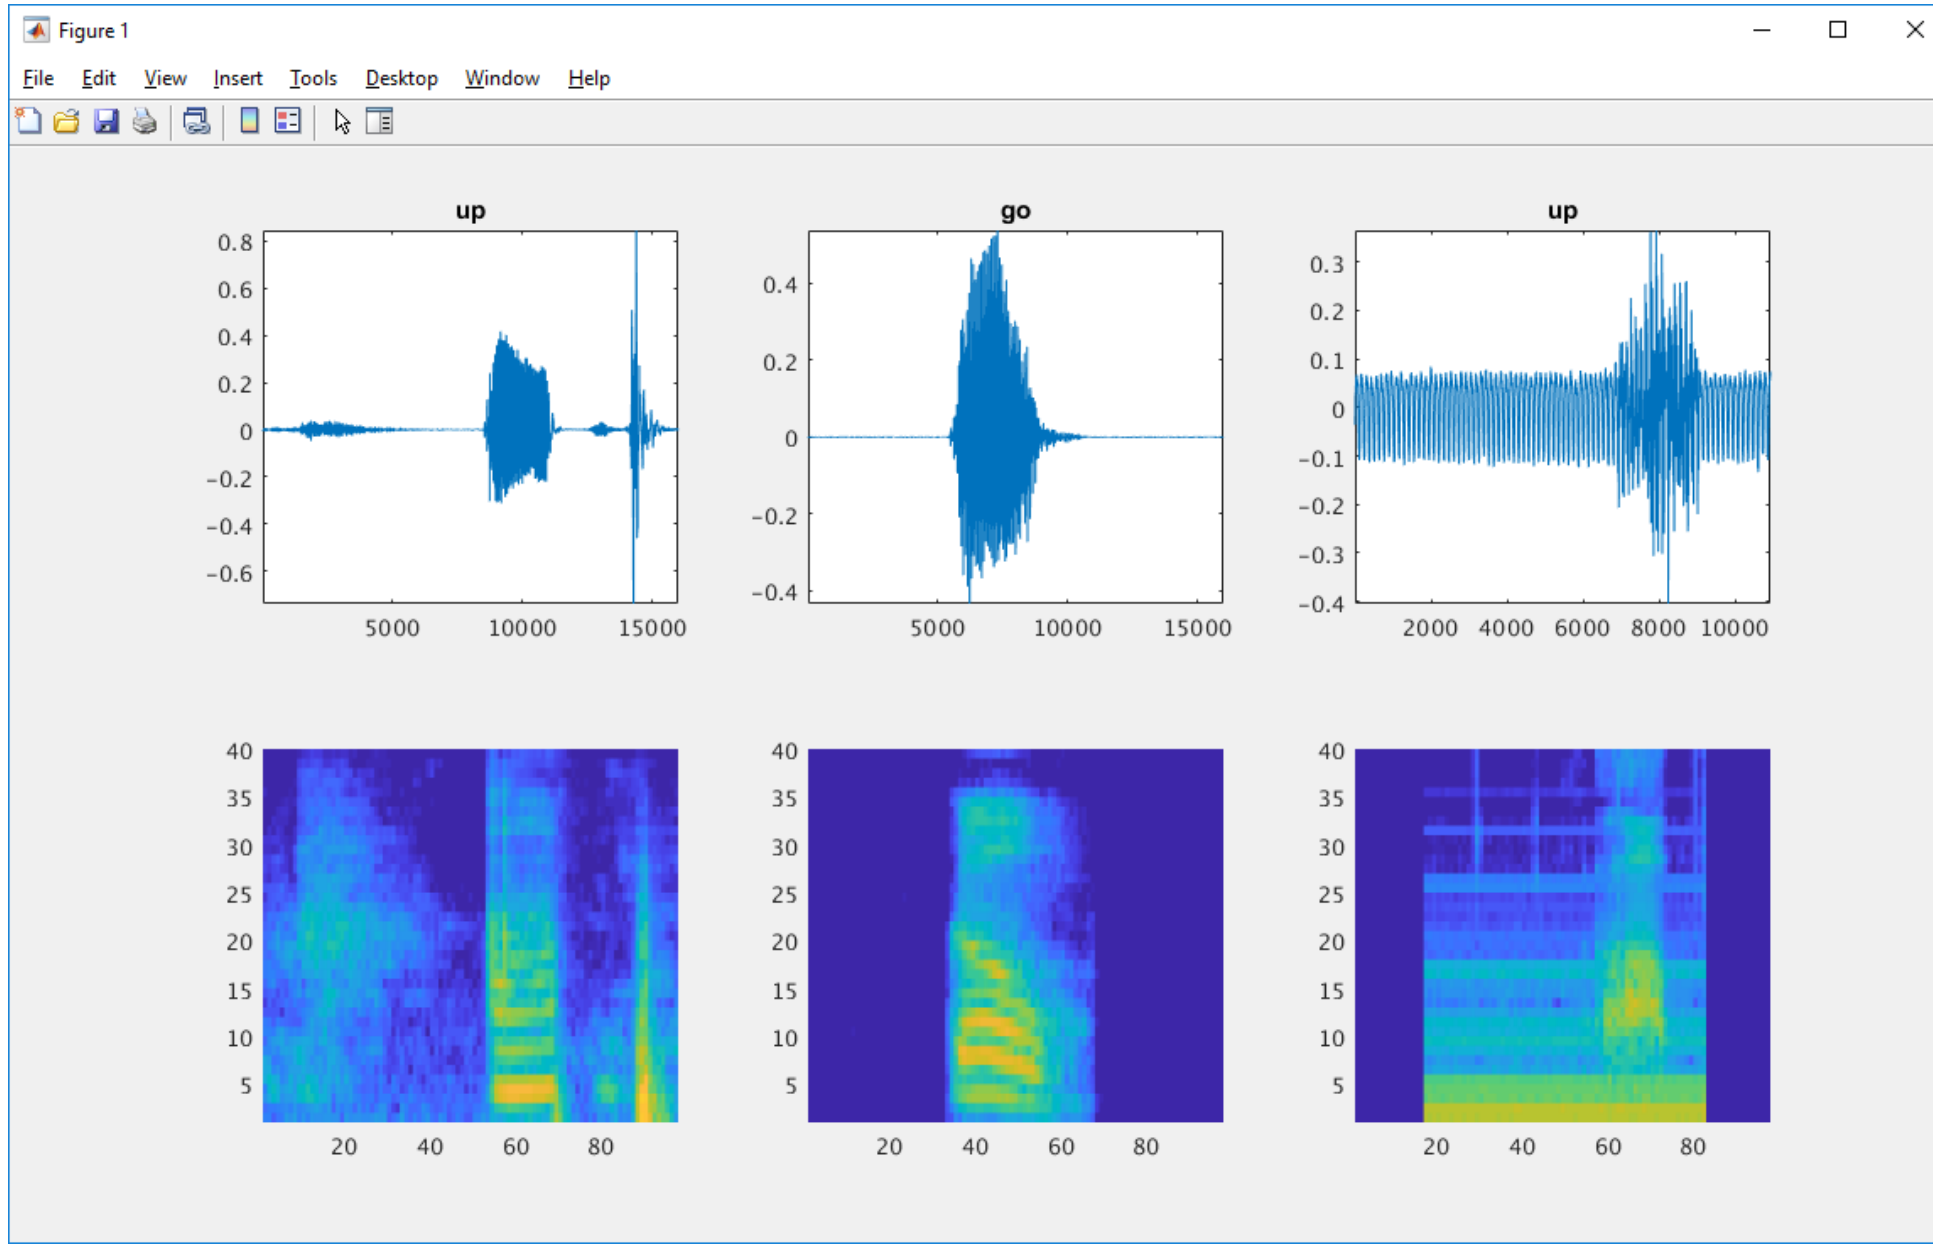
Train a network to classify new objects

Locate & classify objects in images and video



Speech command recognition

Music genre recognition with wavelet Scattering

Demo: Speech Command Recognition



Training Progress (28-Nov-2018 12:48:28)



Results

Validation accuracy: 94.99%
Training finished: Reached final iteration

Training Time

Start time: 28-Nov-2018 12:48:28
Elapsed time: 35 min 38 sec

Training Cycle

Epoch: 25 of 25
Iteration: 5525 of 5525
Iterations per epoch: 221
Maximum iterations: 5525

Validation

Frequency: 221 iterations
Patience: Inf

Other Information

Hardware resource: Single GPU
Learning rate schedule: Piecewise
Learning rate: 3e-05

[i Learn more](#)

Accuracy

— Training (smoothed)
— Training
- - ● - - Validation

Loss

— Training (smoothed)
— Training
- - ● - - Validation

Demos




Image classification using pre-trained network

Train a network to classify new objects

Locate & classify objects in images and video

Speech command recognition

Music genre recognition with wavelet Scattering

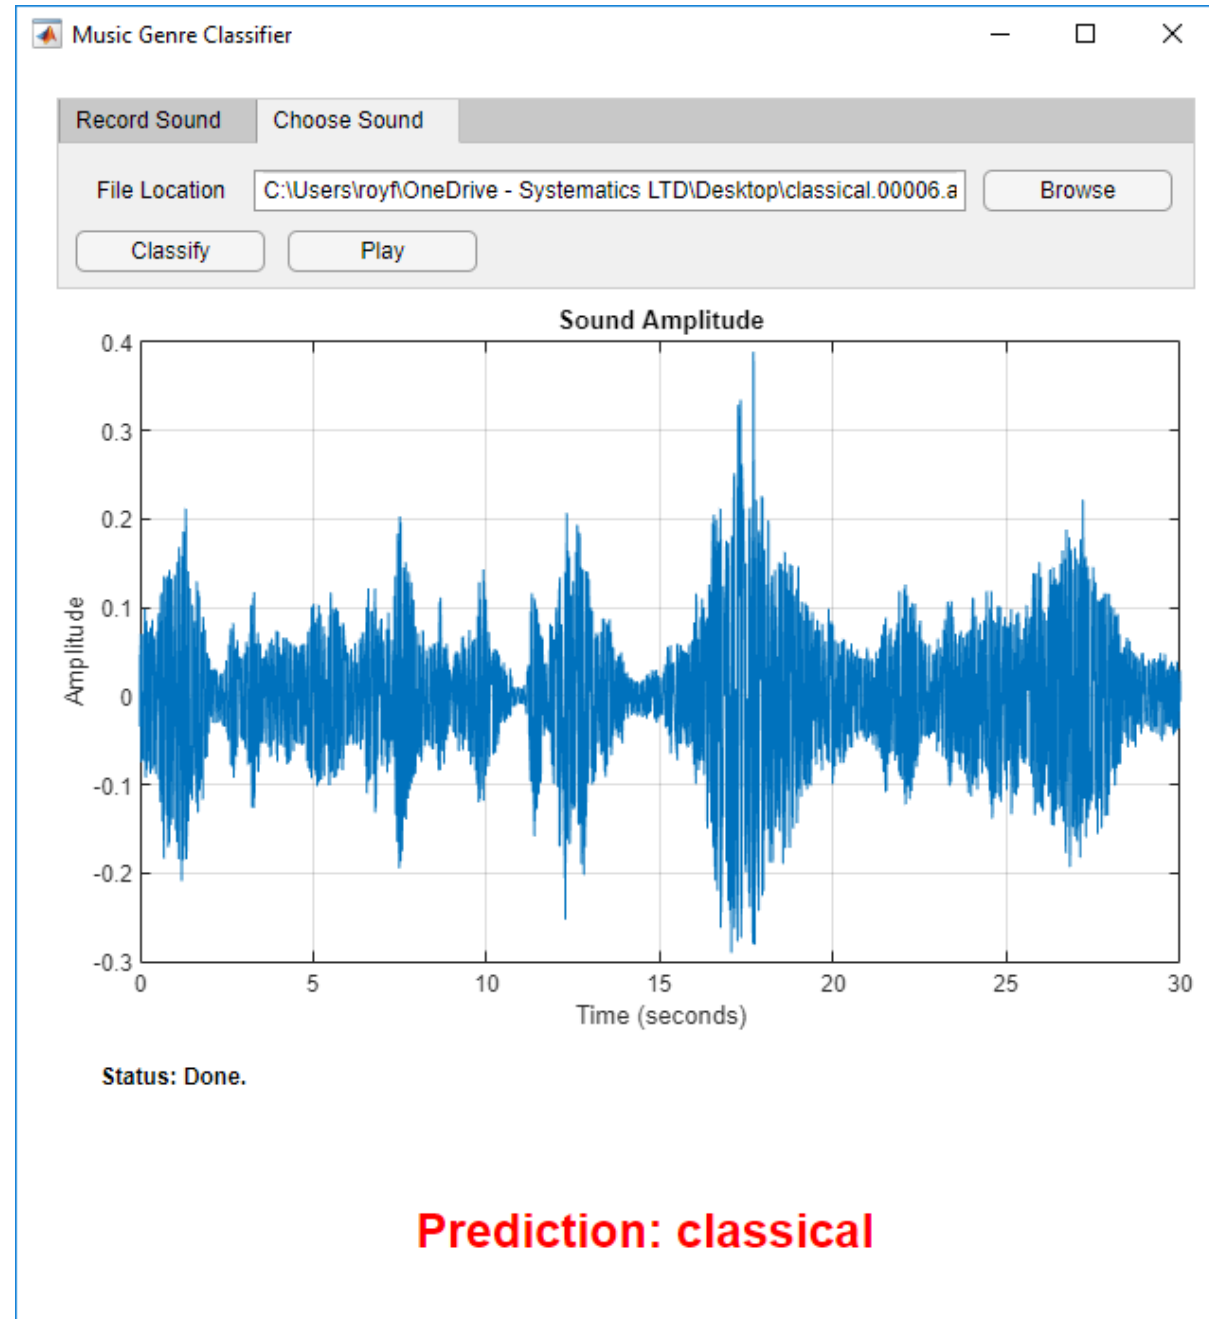
Demo: Music Genre Recognition

- Data: <http://opihi.cs.uvic.ca/sound>

» genres

^

blues	jazz
classical	metal
country	pop
disco	reggae
hiphop	rock



Wavelet Scattering Framework

- Q: What is a deep network ?

A: A network that does:

Convolution → *Filter signal with wavelets*

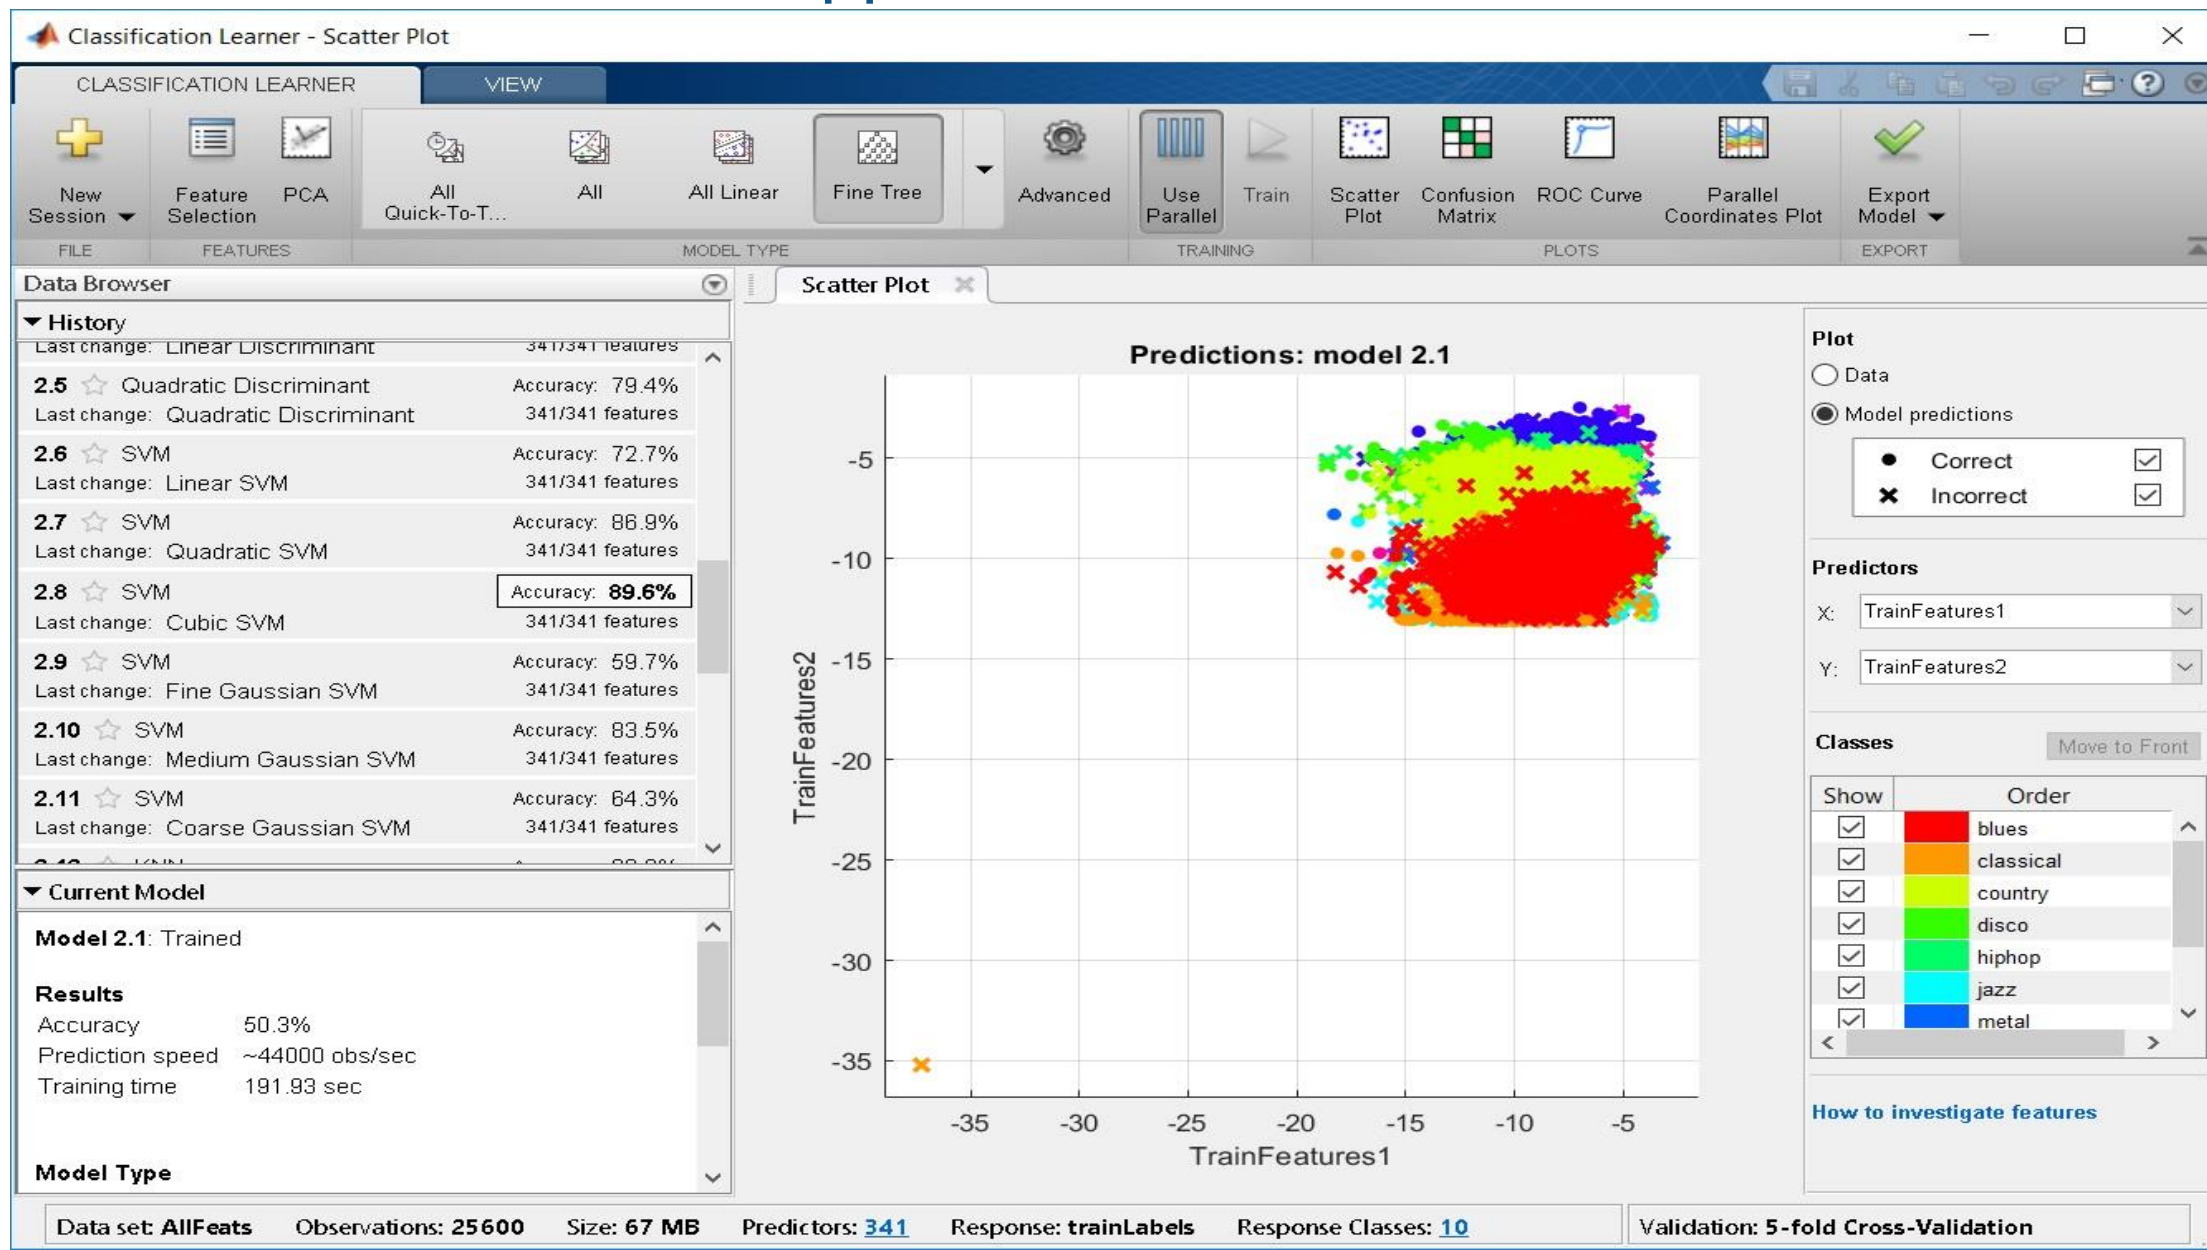
Non-Linearity → *Modulus*

Averaging → *Filter with Scaling function*

- A comparison:

Wavelet Scattering Framework	Convolutional Neural Network
Outputs at every layer	Output at the end
Fixed filter weights	Filter weights are learnt

Classification Learner App



Results - 87% Accuracy!

Music Genre Classification										
blues	18									
classical		19		1						
country	2		18	1		1		1	1	1
disco				17						
hiphop				1	17				1	
jazz		1				19				3
metal					2		20			
pop								17		3
reggae					1			1	16	
rock			2							13
NoUniqueMode								1	2	

blues
classical
country
disco
hiphop
jazz
metal
pop
reggae
rock
NoUniqueMode



MATLAB makes deep learning easy and accessible

Deep Learning Workflow

ACCESS AND EXPLORE
DATA

LABEL AND PREPROCESS
DATA

DEVELOP PREDICTIVE
MODELS

INTEGRATE MODELS WITH
SYSTEMS

Files



Databases



Sensors




Data Augmentation/
Transformation




Labeling Automation



Import Reference
Models




Hardware-Accelerated
Training




Hyperparameter Tuning



Network Visualization



Desktop Apps



Enterprise Scale Systems

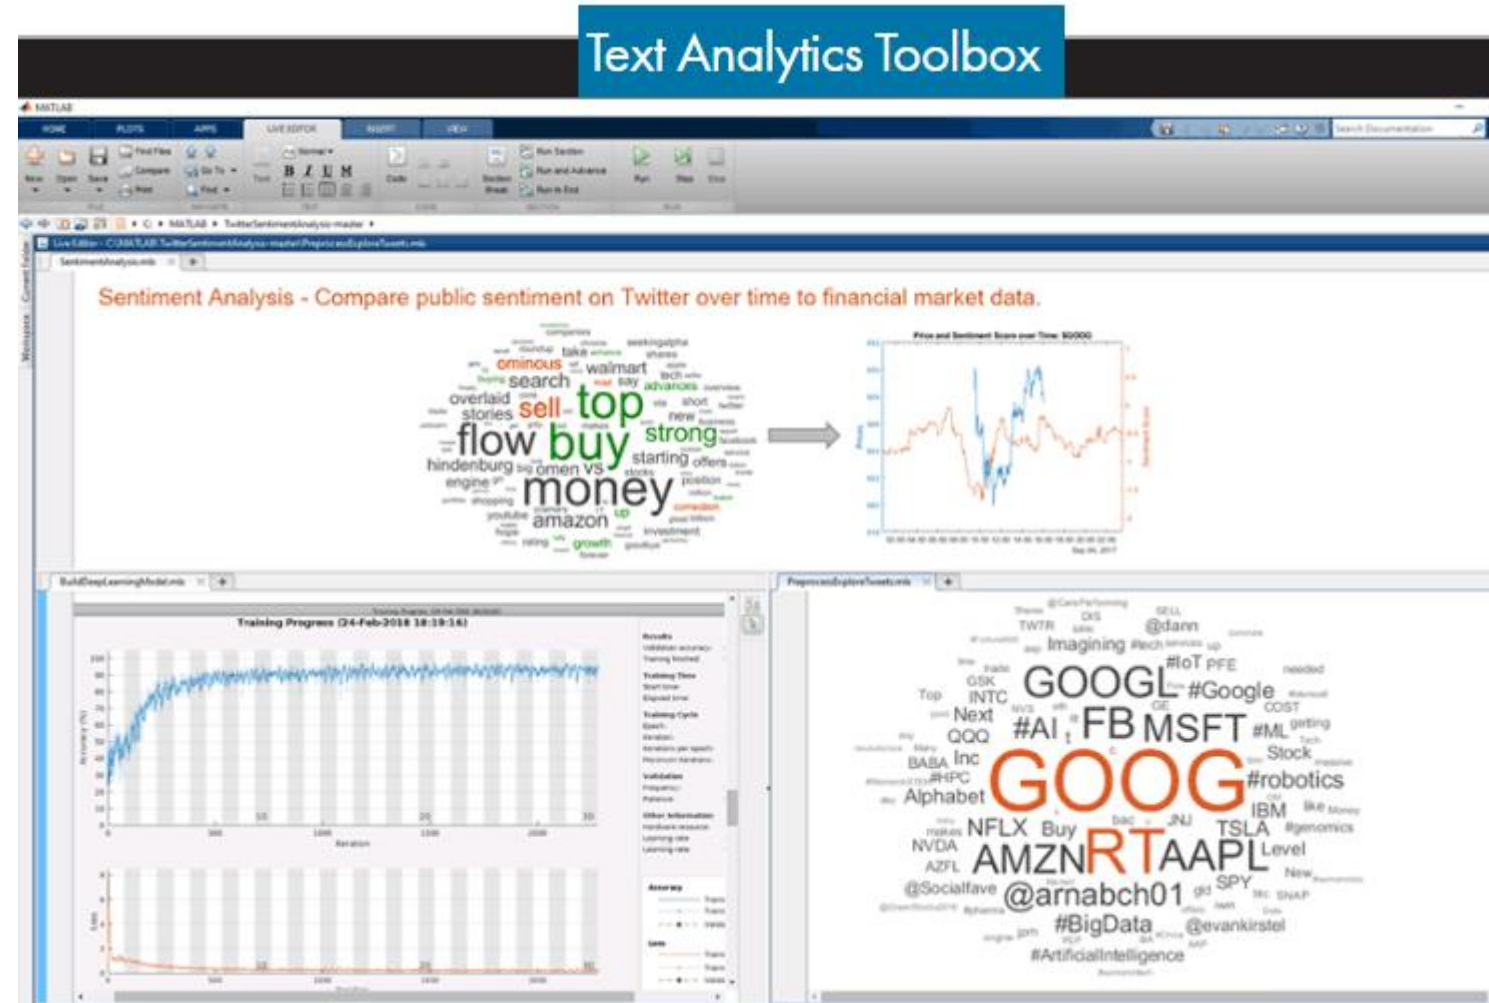
Java
MATLAB
C/C++
Python

Embedded Devices and
Hardware



Types of Datasets

- Images
- 1D Signals
- Numeric
- Text



למידה עמוקה של תחום ה- Deep Learning

מהר יותר, נמוך יותר, חזק יותר עם MATLAB!

8:30 התכנסות ורישום

9:00 הרצאת מבוא: למידה עמוקה - עבר, הווה ועתיד

ערן כז - CTO, חברת VizScribe

רועי אורפייג
ראש צוות עיבוד תמונה בתע"א

ראיה ממוחשבת ולמידה עמוקה, סיסטמטיקס

למידה עמוקה של תחום ה- Deep Learning

מהר יותר, נמוך יותר, חזק יותר עם MATLAB!

8:30 התכנסות ורישום

9:00 הרצאת מבוא: למידה עמוקה - עבר, הווה ועתיד

ערן בוז - CTO, חברת VizScribe

שרון מוסקוביץ
מהנדס עיבוד תמונה בחברת HP

ראיה ממוחשבת ולמידה עמוקה, סיסטמטיקס

10:45 הפסקת קפה

What's New in R2017b?

Custom layer – ממשיך ליצירת סוגים חדשים של שכבות באמצעות שפת MATLAB.

Batch normalization – מאפשר להאיץ את תהליך האימון ולהפחית את הרגישות לאתחול, על ידי שימוש בשכבות אשר מנרמלות את ה-activations והגרדיאנטים המתקדמים ברשת, דבר ההופך את אימון הרשת למשימה פשוטה יותר.

סוגים חדשים נוספים של שכבות – Deconv layer, MaxUnPooling layer (מה שמאפשר לייצר DeconvNet) ועוד...

Semantic Segmentation – סגמנטציה סמנטית הינה טכניקה להפרדה של אובייקט מהרקע ברמת הפיקסל תוך התייחסות זהה לאובייקטים מאותו קלאס (למשל – התייחסות אל שני כיסאות שונים בתור קלאס זהה). בגרסה הקרובה תתווסף אפשרות להוסיף שכבות FCN, SegNet, PixelClassification (מצריך את ה-Computer Vision System Toolbox) ואפשר יהיה ליצור PSPNet (יצריך לבנות את הרשת, המעוניינים יכולים לקבל ממני דוגמה לשימוש ב-Alexnet בתור בסיס; כאמור – לאחר שחרור הגרסה מתוכנן שיחרור של תוסף של ResNet50, מה שיאפשר לשכפל די טוב את ה-PSPNet המקורי). בנוסף, לבעלי ה-Computer Vision System Toolbox - בגרסה יתווספו גם כל מיני פונקציות עזר וכל מיני מטריקות בתחום הסגמנטציה הסמנטית, לרבות IoU / Jaccard (מדד טיב בגילוי אובייקטים – היחס בין החיתוך של ה-bounding box של הגילוי עם זה של ה-ground truth, לבין האיחוד שלהם).

Labeling – כידוע, פרט ל-App לביצוע Labeling לסרטוני וידאו (המהווה חלק מה-Automated Driving System Toolbox) קיים גם ה-App המסייע לביצוע Labeling לתמונות (אשר הינו חלק מה-Computer Vision System Toolbox). לאחרון תתווסף תמיכה בתיוג פיקסלים ואזורים עבור משימות סגמנטציה סמנטית.

Early stopping via validation – יכולת ולידציה אוטומטית לרשת כל מספר איטרציות, ועצירת האימון כאשר מטריקות הולידציה מפסיקות להשתפר. הנ"ל יאפשר להכניס מידע ולידציה לתהליך האימון ולהציג ביצועים ב-plot training accuracy והן על מידע האימון והן על מידע הולידציה (ה-plot המשודרג גם צפוי להכיל לחצן "עצור").

Deep Learning Image Preprocessing – בזמן שהתמונות נקראות ומזונות לתוך האימון - תהיה אפשרות לבצע פעולות גיאומטריות על מנת להגדיל את מידע האימון. הנ"ל גם יוכל לשמש לצורך יצירת מסווג מתוך מאגר תמונות בעלות גדלים שונים, על ידי הפיכתן בקלות לתמונות בעלות גודל זהה.

Bayesian Optimization – מציאת הגדרות אופטימליות לאימון רשתות עמוקות (מצריך את ה-Statistics & Machine Learning Toolbox)

GPU Coder – כלי חדש המאפשר המרה אוטומטית של קוד MATLAB לקוד CUDA אשר יכול לרוץ על מעבדים גרפיים של חברת nVidia. מדובר בהרחבה של כלי ה-MATLAB Coder (המאפשר להמיר קוד MATLAB לקוד C), אשר לפי ה-benchmarks מאפשרת לקוד לרוץ פי 5 יותר מהר מאשר מה שמאפשרת ספריית Caffe2, ופי 7 יותר מהר מאשר TensorFlow (בבדיקה על פעולות הסקה תוך שימוש ב-Alexnet; יודגש שגם ללא הכלי סביבת MATLAB מהירה יותר מאשר שני הכלים האחרים). בנוסף, על פי ה-benchmarks הכלי מאפשר ניצול של פי 3 פחות זיכרון מאשר TensorFlow דורש. ניתן למצוא למטה קישור לפוסט בנושא.

התממשקות עם TensorFlow - Keras לצורך ייבוא מודלים – בהמשך לתמיכה ב-Caffe אשר נוספה ב-R2017a (ראו למטה סקירה של החידושים בגרסה הנ"ל). כך ניתן ליהנות הן מהמודלים המעולים שפותחו בעבר (או יפותחו בהמשך) בסביבות אלה, והן מנוחות העבודה, הויזואליזציות והמהירות של סביבת MATLAB וכן בסופו של דבר לייצר בצורה אוטומטית קוד CUDA בעזרת הכלי המוזכר למעלה. היכולת צפויה להתווסף במהלך חודש אוקטובר. בהקשר זה יש להזכיר שקיימת אפשרות להמיר מודלים מ-PyTorch ל-Keras, ולכן כעת - באמצעות המרה כפולה - אפשר לעבור מ-PyTorch ל-MATLAB.

תמיכה בארכיטקטורות מתקדמות של רשתות –

RNN היא רשת בעלת לולאות שמסוגלת להתמודד יותר בקלות ויותר בטבעיות עם מידע רציף, כמו וידאו, טקסט, ואודיו. כלומר – מאפשרת לנצל את המידע שנאסף במילה הקודמת או בפריים הקודם של הווידאו, על מנת להבין את המילה הבאה או הפריים הבא. בגרסה החדשה צפויה תמיכה ב-LSTM - מקרה מיוחד של RNN - אשר מצליח להשתמש במידע שנלמד בתחילת רצף ארוך - גם בשלב יותר מאוחר ברצף. משמש לתרגום, זיהוי כתב יד, זיהוי קול, סיווג תמונות, חיזוי תגיות ועוד.

DAG - רשת שבה הקלט של שכבה יכול להגיע ממספר שכבות, והפלט שלה יכול להגיע אל מספר שכבות, ללא משוב.

GoogLeNet – רשת DAG קטנה, מהירה ומדויקת, אשר זכתה בתחרות ILSVRC בשנת 2014.

הנ"ל בהמשך לתמיכה ב-VGG שנוספה ב-R2017a והרחיבה את התמיכה ב-Alexnet. שימו לב שבמהלך חודש אוקטובר צפויה להתווסף גם תמיכה ב-ResNet50 (רשת מקבילית עמוקה מאוד, 177 שכבות, שאומנה באמצעות למעלה ממיליון תמונות, וזכתה ב-ILSVRC לשנת 2015) בתור Support Package.

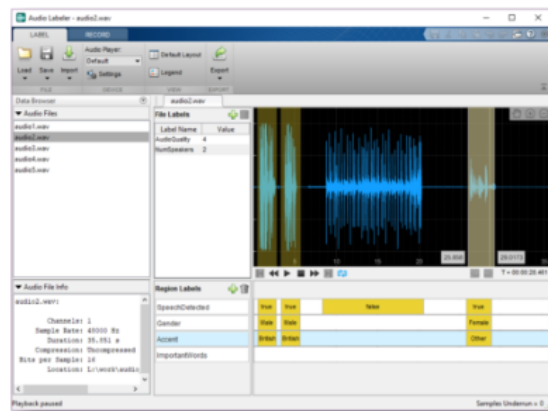
תמיכה ב-InceptionV3 צפויה להתווסף בסביבות סוף השנה.

What's New in R2018a?

- **ולידציה של Custom Layers** – כזכור, החל מהגרסה הקודמת ניתן לייצר סוגים חדשים של שכבות באמצעות שפת MATLAB, והחל מהגרסה הנוכחית – ניתן לבצע ולידציה אוטומטית לטיפוסי המידע והמימדים, לבחון תאימות מבחינת עבודה עם GPU ולוודא שהגרדיאנטים הוגדרו כנדרש
- **תמיכה של רשתות CNN במידע תמונתי בעל יותר מ-3 ערוצים** (מולטיספקטרי)
- **שיפור מהירות ריצה על CPU באימון ו-Inference**
- **אופטימיזציות חדשים** – Adam ו-RMSProp (בנוסף ל-SGDM)
- **הקפאת שכבות** – נוספה הפקודה freezeWeights שגורמת לכך שהפרמטרים של שכבות שרוצים להקפיא – פשוט לא יתעדכנו במהלך האימון. ומכיוון שלא מחשבים את הגרדיאנטים של השכבות האלה – האימון יהיה מהיר יותר. ואגב, אם ה-data set החדש שבו משתמשים ב-transfer learning הוא קטן, אז הקפאה של השכבות הראשונות יכולה למנוע overfitting שלהן אליו.
- **שימוש בטכניקת Gradient Clipping** כדי למנוע "התפוצצות" של הגרדיאנטים ברשתות עמוקות במיוחד (שימושי לרוב בעבודה עם RNNs)
- **LSTM** – תמיכה ברשתות LSTM עם **שכבת רגרסיה בקצה**; תמיכה ברשתות LSTM **דו-כיוונית** (כדי ללמוד מכל ההקשר של הרצף)

- **תצוגה גרפית של הרשת בעזרת ה-Network Analyzer App** – לצורך איתור בעיות אפשריות לפני ביצוע האימון
- **יצירה, אימון וניתוח של רשתות DAG** – אימון מהיר יותר (בעזרת GPUs), חישוב והצגה של activations של שכבות ביניים, החלפה פשוטה יותר של שכבות בעת עריכת רשתות מסוג זה
- **המרה של קוד MATLAB לקוד CUDA** – אפשר כעת להמיר גם רשתות DAG ולייצר קוד CUDA מתוך רשתות נפוצות נוספות כמו SqueezeNet, GoogLeNet, ResNet (50/101), SegNet, בנוסף, יש כעת אפשרות להשתמש ב-TensorRT בעת יצירת קוד CUDA, מה שיאפשר קבלת קוד CUDA מהיר במיוחד בנוסף, יש כעת אפשרות להשתמש ב-CUDA
- **תמיכה ביצירת קוד עבור חומרות נוספות** – ה-GPU Coder מסוגל כעת לייצר קוד C עבור רשתות גם עבור מעבדים של אינטל (Intel Xeon CPU, למשל) ופלטפורמות Am (Neon), דבר שיאפשר, למשל, לטרגט טלפון אנדרואיד
- **יכולות חדשות באפליקציות התיגו** – ה-Ground Truth Labeler תומך כעת בסגמנטציה ברמת הפיקסל, ב-Sub-Labels וכן בצירוף labels ל-Attributes (הנ"ל יכולים להיות ערכים נומרים ועשויים לסייע בתרחישי תיוג לצורך משימות רגרסיה). גם הוא וגם ה-Image Labeler מקלים כעת עוד יותר על ביצוע תיוג ברמת הפיקסל, באמצעות אופציית Smart-Polygon המאפשרת לעדן את הסגמנטציה בתוך איזור עניין על ידי סימון פיקסלים בתור רקע או אובייקט


What's New in R2018b?



בהקשר זה יוזכר ה-Audio Datastore שהתווסף ל-Audio System Toolbox בגרסה זו, ומאפשר לנהל אוספים גדולים של קבצי אודיו (יצירת labels על סמך שמות התיקיות, דגימה של קבצים בצורה אקראית, גישה מקבילית לצורך עיבוד מקדים או חילוף פיצ'רים או אוגמנטציה וכו').

הרשום בסעיף זה מהווה "טעימה" לתחום מיקוד משני שהוסיפה MathWorks בכל הקשור ליכולות הכלים של החברה בעולם ה-Deep Learning – לא עוד "רק עיבוד תמונה וראיה ממוחשבת" – אלא גם **יכולות בתחומים עיבוד אות, ניתוח טקסט ודיבור**.

- **Video Labeler App** – ממשק גרפי לתיוג רצפי תמונות וסרטוני וידאו המכיל את היכולות השימושיות של ה-Ground Truth Labeler אך אינו מחייב רישיון ל-Automated Driving System Toolbox. מאפשר אוטומציה של תהליך התיוג באמצעות עקיבה אחר אובייקטי עניין וכן מאפשר תיוג ברמת הפיקסל לצורך ביצוע Semantic segmentation. למידע נוסף – [יש לחנוך פה](#).



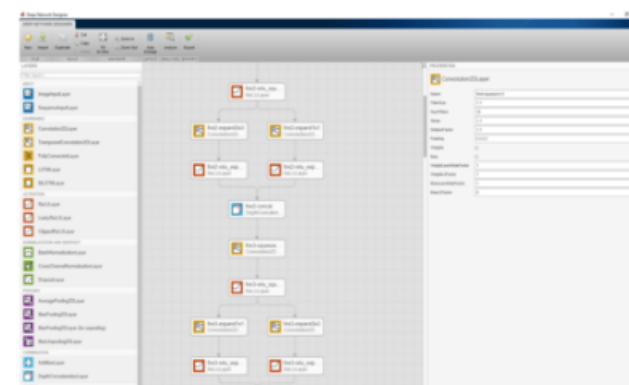
גרסת R2018b של כלי MathWorks, אשר שוחררה לפני מספר שבועות, כוללת יכולות חדשות רבות ותיקוני באגים בכלים הקיימים, ואף מספר כלים חדשים (לסקירת יכולות הגרסה – [לחצו פה](#)). מבחינת תחום ה-Deep Learning – כמו בגרסה הקודמת ([לחצו לסקירה](#)) – גם בגרסה השנייה לשנת 2018 התחום מקבל פוקוס מיוחד. למעשה, לאור העובדה של-Neural Network Toolbox נוספו כל כך הרבה יכולות בתחום ה-Deep Learning בתקופה האחרונה, עד שתחום זה הפך למסה העיקרית של הכלי – החברה החליטה לשנות את שם הכלי ל-**Deep Learning Toolbox**.

אז...מה נשתנה בתחום ה-Deep Learning בגרסת R2018b?

להלן החידושים המרכזיים:

1. **תוספת Apps** – כדי להקל על השימוש ולשפר את היעילות. ה-Apps החדשים הינם:

- **Deep Learning Designer** – ממשק גרפי לעבודה עם רשתות – ניתן לבנות רשת באמצעות גרירת אבני בניין וחיבורן, ללא הקלדת פקודות; ניתן לייבא רשת מאומנת ולערוך אותה בקלות לצורך ביצוע Transfer Learning; ניתן לנתח את הרשת כדי לוודא שהארכיטקטורה מוגדרת כהלכה ולאתר בעיות לפני תחילת האימון (על ידי פתיחת ה-Network Analyzer ישירות מתוך App זה); וניתן כמובן לייצא את הרשת. למידע נוסף: [יש לחנוך פה](#).




- **Audio Labeler** – ממשק גרפי המקל על הכנת Labeled data sets לצורך הפעלת טכניקות מתחום ה-Deep Learning על סיגנלים חד-ממדיים (אודיו) – אפשר לעבוד על אוספי הקלטות או להקליט ישירות עם ה-App; אפשר לנווט בצורה אינטראקטיבית; אפשר להגדיר וליישם labels על קבצים שלמים או על איזורים בתוך קבצים; אפשר לייבא וליצא תיקיות אודיו, הגדרות של labels ו-datastores. למידע נוסף: [יש לחנוך פה](#).

What's New in R2018b?

2. קל יותר לאמן בענן ועל HPC Boxes (כמו Nvidia DGX) לצורך בדיקת היתכנות לפני שמשקיעים ברכישת חומרה פרטית ולצורך האצת האימון.

- דרך אחת – MATLAB Reverence Architectures ל- Azure ו- Amazon – מאפשרת לקבל בקלות מכונה וירטואלית שעובדת על כל אחד מה-domain האלה. למידע נוסף – [יש לחנוך פה](#).
- דרך שניה – קונטיינרים ל- NGC (Nvidia GPU Cloud) – יש תמיכה ב- Nvidia DGX.


5. מהירות Inference – גם בגרסה החדשה נשמרה העליונות של ה- GPU Coder מבחינת קצבי Inference בהשוואה לסביבות החינמיות:



HWB: Intel® CPU 2.8 GHz - NVIDIA driver: CUDA8 - cuDNN 7 - Frameworks: TensorFlow 1.0.2, MXNet 1.2.1, PyTorch 0.2.1

3. אינטראופריליות עם סביבות Deep Learning מבוססות Python כמו Keras-Tensorflow, PyTorch ואחרות – R2018b

הינה הגרסה הרשמית הראשונה של כלי MathWorks שכוללת את התמיכה בפורמט ONNX מאז שתמיכה זו שוחררה כ- Support Package. הפיצ'ר מאפשר גישה לכל תוצאות המחקרים האחרונים הזמינים בסביבות Deep Learning נפוצות, מאפשר שיתוף פעולה בין חברי צוות שמעדיפים לעבוד כל אחד בסביבה אחרת, ומאפשר ניצול יכולות MATLAB בתחומים כמו תיוג או עיבוד מקדים או יצירת קוד והורדה למערכת Embedded. כלומר – לא חייבים לבחור סביבה אחת או סביבה אחרת, אפשר ליהנות מכל העולמות!



6. תמיכה ביצירת קוד עבור GPU-ים של Nvidia, מעבדי Intel ופלטפורמות ARM מתוך מגוון רחב יותר של סוגי שכבות (טבלה מצורפת למטה). למציאת הרשימה המלאה עבור כל target יש להשתמש בפקודה `getDeepLearningLayers`.

	cuDNN	TensorRT	MKLDNN	ARM
Dilated Convolution	R2018b	R2018b	R2018b	R2018b
Scaling layer	R2018b	R2018b	R2018b	R2018b
Depth Concatenation layer	✓		R2018b	R2018b
Addition layer	✓		R2018b	R2018b
Pixel Classification layer	✓		R2018b	R2018b
Transposed Convolution layer	✓	R2018b	R2018b	R2018b
Max pooling with indices	✓		R2018b	R2018b
LeakyReLU	✓	R2018b	✓	

4. Out of box targeting for popular GPU boards – ה- GPU Coder הוא כלי של MathWorks המאפשר המרת קוד MATLAB לקוד CUDA עבור GPU-ים של חברת Nvidia. על מנת לחסוך זמן יקר שכרוך ב- setup וחיבור לכרטיסי חומרה במהלך תהליך הפיתוח, בגרסה החדשה של ה- GPU Coder נוספו support packages לפלטפורמות Nvidia Jetson ו- Nvidia Drive.

What's New in R2018b?

7. **Network Assembly** משכבות ומשקולות מיובאות, **ללא צורך באימון** – שימושי למשל למי שרוצה ליבא רשת מסביבת Deep Learning מבוססת Python **ומייד** להמיר אותה בצורה אוטומטית לקוד כמו קוד CUDA. בעזרת הממשק עם ONNX המוזכר למעלה אפשר לטעון לתוך MATLAB רשת שאומנה בסביבה מסוימת, וכעת לאחר הפעלת הפקודה assembleNetwork אפשר לייצר מהרשת הזו קוד באופן **מייד**. כלומר אם בעבר היה צריך לאמן את הרשת המיובאת epoch אחד, עכשיו בעזרת פקודת assembleNetwork אפשר לייבא **ומייד** להשתמש.

8. יכולות יזואליזציה –

- נוספה הפונקציה confusionchart אשר מספקת דרך נוחה לחקור את החיזויים של הרשת לעומת התגיות הנכונות שאותן היא היתה אמורה לחזות (בבעיות סיווג). ניתן לשלוט על מאפייני ה-confusion matrix, לצפות בסיכומים סטטיסטיים, לבצע מיונים וכו'. למידע נוסף – [יש לחנוך פה](#).

True class	bird	89	43	69	76	33
	cat	43	34	40	81	95
	dog	83	2	74	40	80
	fish	40	28	71	38	68
	tree	77	20	45	22	44
		bird	cat	dog	fish	tree
		Predicted class				

- ניתן לבצע ויזואליזציה של הפלט של שכבות ביניים ברשתות DAG

9. **רשתות מאומנות זמינות לשימוש** – מאז הגרסה הקודמת נוספה תמיכה במגוון רשתות חדשות, כמו ResNet-18, DenseNet-201, Inception-ResNet-v2, SqueezeNet הרשתות המאומנות הללו יכולות לשמש כנקודת התחלה עבור עבודה בגישת Transfer Learning, וניתן לטעון כל אחת מהן תוך שימוש בשורת קוד אחת. לרשימה המלאה של כל ה-Pre-trained Networks הזמינות – [לחצו פה](#).

10. **וליצייט רשתות LSTM/BiLSTM עבור מידע time series בצורה אוטומטית במהלך האימון** – מסייעת למניעת overfitting.

ויש כמובן עוד חידושים עליהם ניתן לקרוא בתיעוד.

R2019a Features



- Reinforcement Learning Toolbox
- 3D
- Automatic MATLAB code generation from the network that was designed using the Deep Network Designer
- YOLOv2 Object Detector – training & CUDA code generation
- MobileNet-v2, Xception, and Places365-GoogLeNet
- Create custom layers with multiple inputs or multiple outputs
- Signal Labeler
- And more...

Gartner recognizes MathWorks as a “**Visionary**” and one of the top data science platforms in its 2019 research report

- Strength of MATLAB in asset-centric industries and for engineering-focused audiences
- Strengths in operationalization as a fully integrated step (deployment and enterprise integration), data preparation, **machine learning** and **deep learning**

Figure 1. Magic Quadrant for Data Science and Machine Learning Platforms




Check Out Deep Learning in MATLAB, GPU Coder and Free Hands-On

MathWorks® Products Solutions Academia Support Community Events

Deep Learning Search MathWorks.com

Overview Features Examples Models Videos and Tutorials Trial software Contact sales



MATLAB for Deep Learning
Design, build, and visualize convolutional neural networks

Deep learning in MATLAB

MathWorks® Products Solutions Academia Support Community Events

GPU Coder Search MathWorks.com

Overview Features Code Examples Videos Product Pricing Trial software Contact sales

Generate CUDA code for NVIDIA GPUs

GPU Coder™ generates optimized CUDA® code from MATLAB® code for deep learning, embedded vision, and autonomous systems. The generated code calls optimized NVIDIA CUDA libraries, including cuDNN, cuSolver, and cuBLAS. It can be integrated into your project as source code, static libraries, or dynamic libraries, and can be used for prototyping on GPUs such as the NVIDIA Tesla® and NVIDIA Tegra®. You can use the generated CUDA within MATLAB to accelerate computationally intensive portions of your MATLAB code. GPU Coder lets you incorporate legacy CUDA code into your MATLAB algorithms and the generated code.

When used with Embedded Coder®, GPU Coder lets you verify the numerical behavior of the generated code via software-in-the-loop (SIL) testing.



GPU Coder Capabilities
[Learn more](#)

Introducing Deep Learning with MATLAB
[Download ebook](#)

GPU Coder

» MATLAB academy Deep Learning Onramp

Deep Learning Onramp

1. Introduction

Familiarize yourself with Deep Learning concepts and the course.

[Deep Learning for Image Recognition Course Overview](#)

2. Using Pretrained Networks

Perform classifications using a network already created and trained.

[Course Example - Identify Objects in Some Images Making Predictions](#)
[CNN Architecture](#)
[Investigating Predictions](#)

3. Managing Collections of Data

Perform classifications using a network already created and trained.

[Image Datastores](#)
[Preparing Images to Use as Input](#)
[Processing Images in a Datastore](#)
[Create a Datastore Using Subfolders](#)

4. Performing Transfer Learning

Modify a pretrained network to classify images into specified classes.

[What is Transfer Learning](#)
[Components Needed for Transfer Learning](#)
[Preparing Training Data](#)
[Modifying Network Layers](#)
[Setting Training Options](#)
[Training the Network](#)
[Evaluating Performance](#)
[Transfer Learning Summary](#)


5. Conclusion

Learn next steps and give feedback on the course.

[Project - Roundworm Vitality](#)
[Further Deep Learning Tasks](#)
[Survey](#)


matlabacademy.mathworks.com/


More Information

- Website:
www.mathworks.com
- **MATLAB With Fun** Blog:
www.systematics.co.il/matlab-blog
- **Linked in** Group:
MATLAB & Simulink users in Israel 
- Seminars:
www.systematics.co.il/products/mathworks/events/
- Courses:
www.systematics.co.il/courses/mathworks/
- Videos:
www.youtube.com/user/MatlabSystematics/videos
- Support & Sales: 03-7660111

Code for demos 1-3 (image processing):
goo.gl/GCHbAa


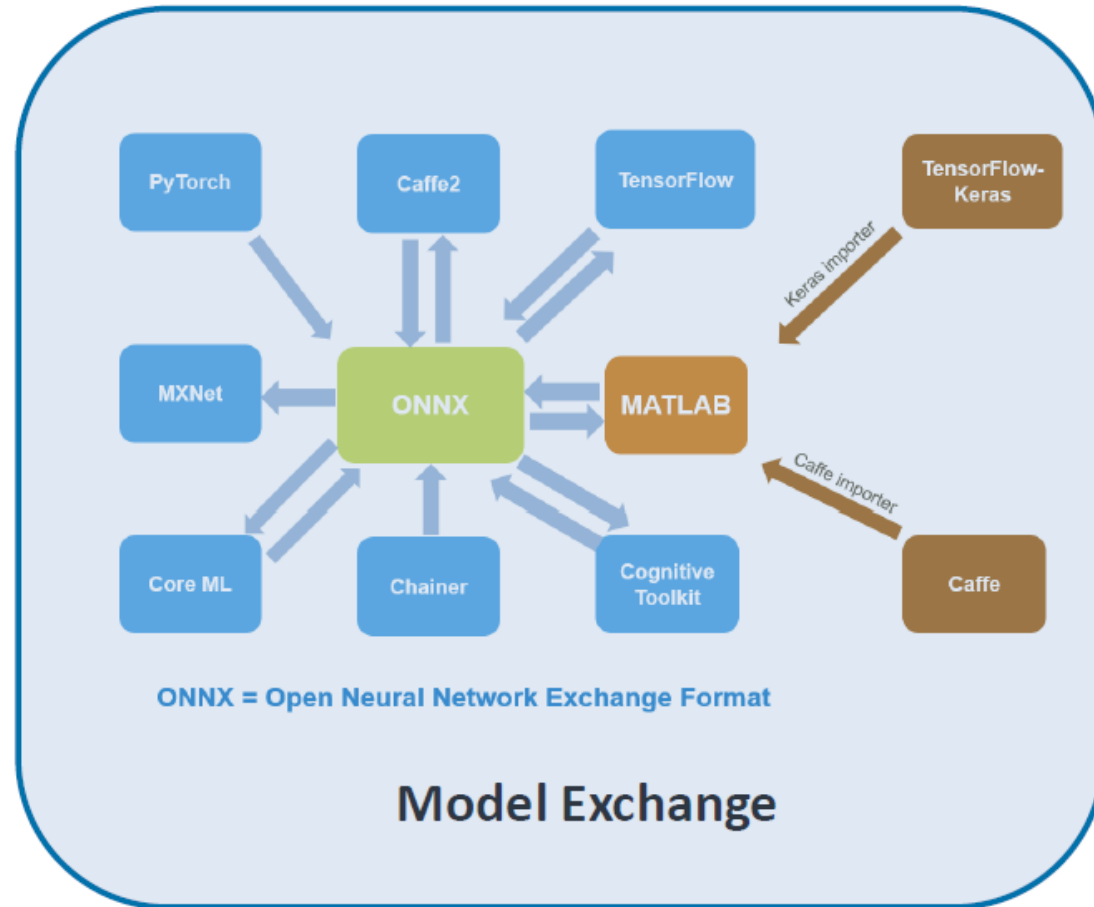
Code for demo 5 (signal processing):
goo.gl/nSRgMu



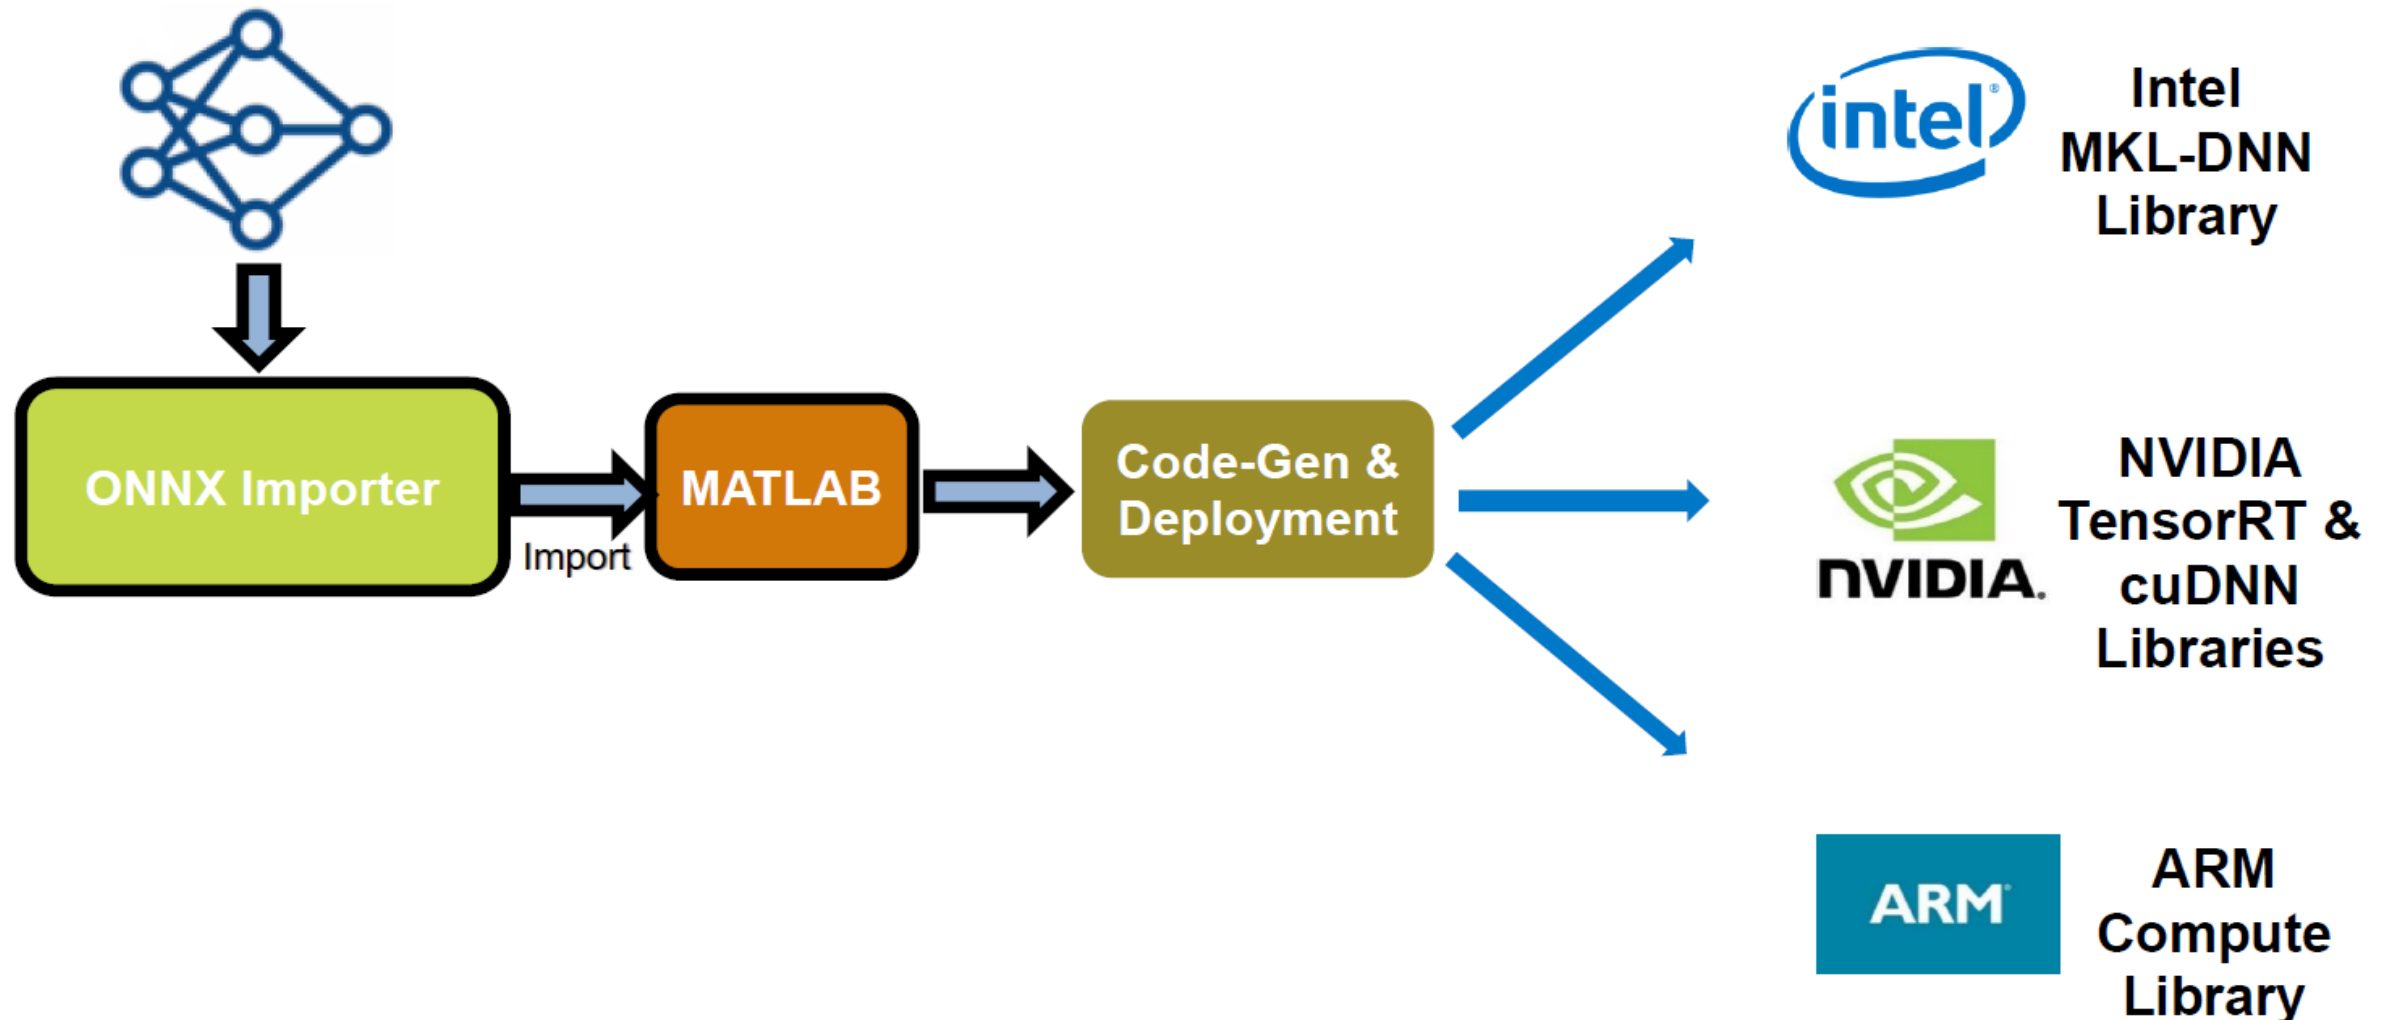


Thank You

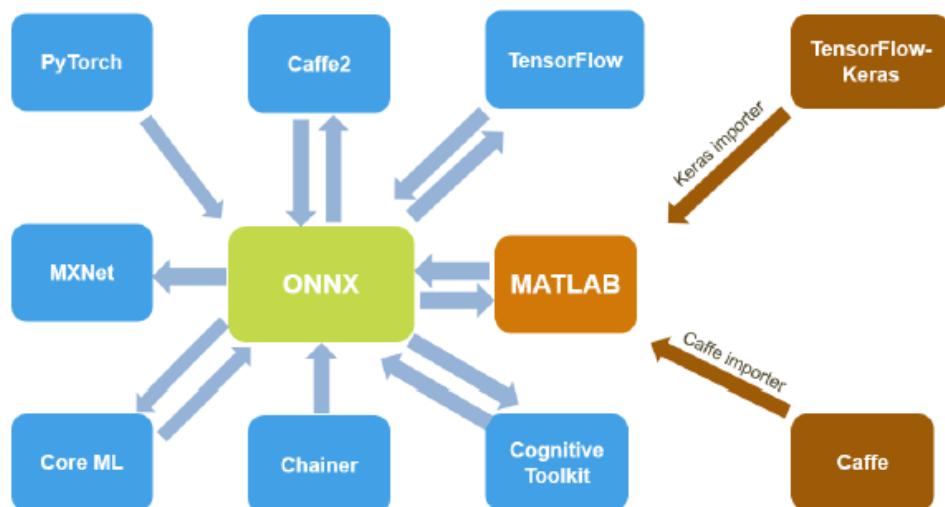
Two Ways to Work with TensorFlow and PyTorch



Example

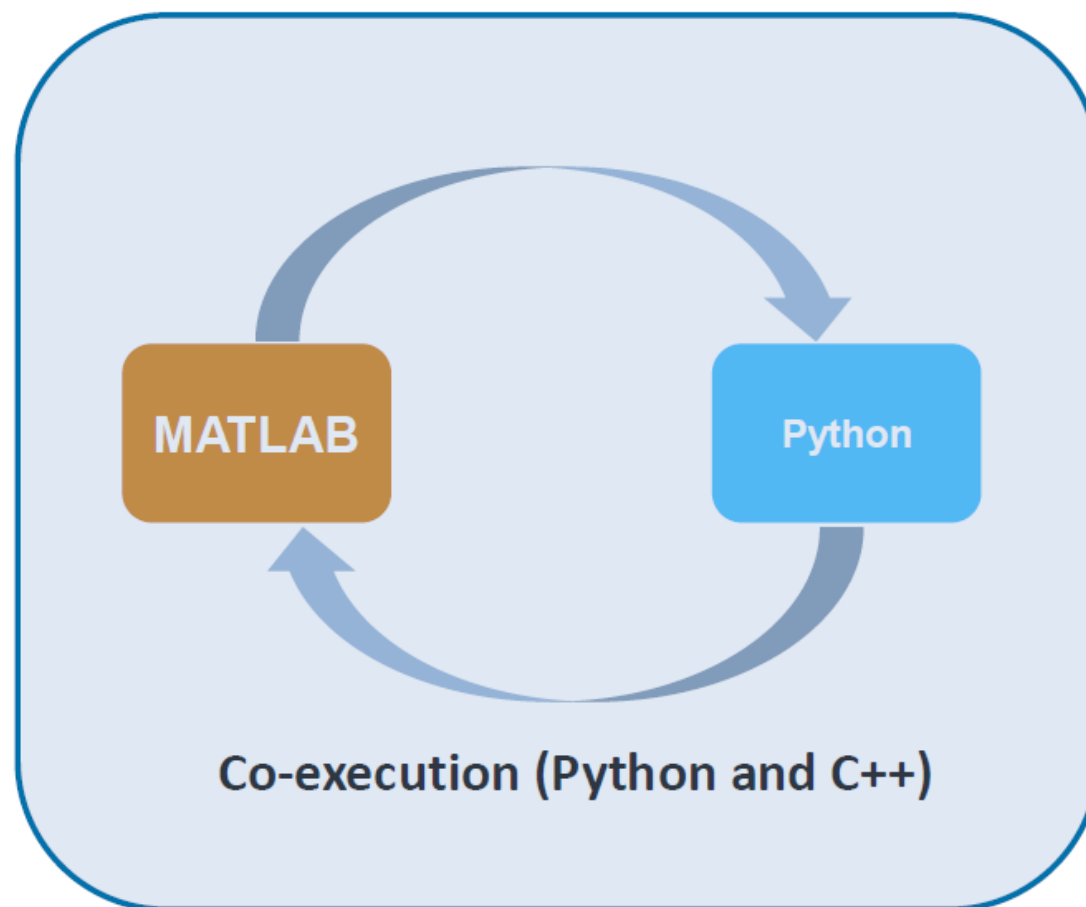


Two Ways to Work with TensorFlow and PyTorch

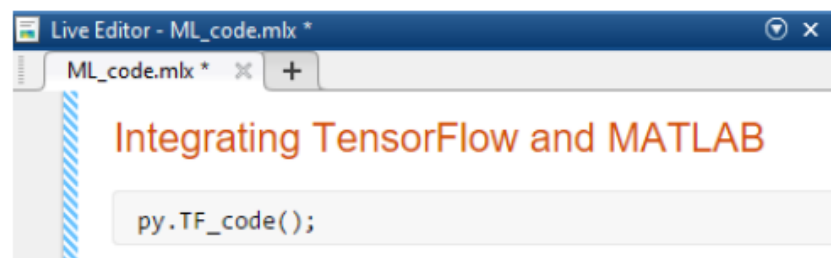


ONNX = Open Neural Network Exchange Format

Model Exchange



MATLAB-Python Co-Execution



TF_code.py

1. Copy code into a .PY file
2. Wrap entry point in a function

```
import tensorflow as tf
from tf import keras
```

```
def myTFCode():
    for x in y:
        a.foo()
```

```
def foo(x):
    return x + 1
```

3. Add module to Python path and then call from MATLAB via:

```
py.myModule.myTFCode();
```